Python 3

爬虫、数据清洗与可视化实战

零一　韩要宾　黄园园　著

電子工業出版社
Publishing House of Electronics Industry
北京•BEIJING

VISIT…

内 容 简 介

本书是一本通过实战教初学者学习采集数据、清洗和组织数据进行分析及可视化的 Python 读物。书中案例均经过实战检验，笔者在实践过程中深感采集数据、清洗和组织数据的重要性，作为一名数据行业的“码农”，数据就是沃土，没有数据，我们将无田可耕。

本书共分 11 章，6 个核心主题：其一是 Python 基础入门，包括环境配置、基本操作、数据类型、语句和函数；其二是 Python 爬虫的构建，包括网页结构解析、爬虫流程设计、代码优化、效率优化、容错处理、反防爬虫、表单交互和模拟页面点击；其三是 Python 数据库应用，包括 MongoDB、MySQL 在 Python 中的连接与应用；其四是数据清洗和组织，包括 NumPy 数组知识、pandas 数据的读写、分组变形、缺失值异常值处理、时序数据处理和正则表达式的使用；其五是综合应用案例，帮助读者贯穿爬虫、数据清洗与组织的过程；最后是数据可视化，包括 Matplotlib 和 Pyecharts 两个库的使用，涉及饼图、柱形图、线图、词云图、地图等图形，帮助读者进入可视化的殿堂。

本书以实战为主，适合 Python 初学者及高等院校的相关专业学生，也适合 Python 培训机构作为实验教材使用。

未经许可，不得以任何方式复制或抄袭本书之部分或全部内容。
版权所有，侵权必究。

图书在版编目（CIP）数据

Python 3 爬虫、数据清洗与可视化实战 / 零一，韩要宾，黄园园著. —北京：电子工业出版社，2018.3
ISBN 978-7-121-33359-0

Ⅰ. ①P… Ⅱ. ①零… ②韩… ③黄… Ⅲ. ①软件工具－程序设计 Ⅳ. ①TP311.561

中国版本图书馆 CIP 数据核字(2017)第 321885 号

策划编辑：张慧敏
责任编辑：牛　勇
印　　刷：
装　　订：
出版发行：电子工业出版社
　　北京市海淀区万寿路 173 信箱　　邮编：100036
开　　本：787×980　1/16　印张：13.25　字数：200 千字
版　　次：2018 年 3 月第 1 版
印　　次：2018 年 3 月第 1 次印刷
印　　数：3000 册　　定价：49.00 元

凡所购买电子工业出版社图书有缺损问题，请向购买书店调换。若书店售缺，请与本社发行部联系，联系及邮购电话：（010）88254888，88258888。

质量投诉请发邮件至 zlts@phei.com.cn，盗版侵权举报请发邮件至 dbqq@phei.com.cn。

本书咨询联系方式：010-51260888-819，faq@phei.com.cn。

Python 是一种解释型、面向对象的动态数据类型高级程序设计语言。从 20 世纪 90 年代初 Python 语言诞生至今，它逐渐被广泛应用于各个领域，比如桌面应用开发、游戏开发、Web 开发、网络爬虫、数据统计分析、自然语言处理、机器学习、深度学习、人工智能等。由于 Python 语言的简捷性、易读性及可扩展性，在国外用 Python 进行科学计算的研究机构日益增多。一些知名大学甚至采用 Python 语言教授程序设计课程，例如麻省理工学院的计算机科学及编程导论课程。

在数据科学领域，Python 的发展势头十分迅猛。一方面，Python 拥有各种开源的网络爬虫框架，可以帮助数据科学家快速收集数据；另一方面，Python 在机器学习和深度学习方面有很多成熟的拓展包，可以帮助数据科学家完成各类数据分析任务，无论是简单的线性回归，还是复杂的深度学习网络构建。

Stack Overflow 最新调查显示，Python 已经成为快速发展的主流编程语言，也是高收入国家网民访问 Stack Overflow 网站过程中，点击量最高的标签。由此可见，Python 将必成为各个领域的程序员需要掌握的技能之一。

黄志洪

著名数据分析网站炼数成金创始人

我最早是通过《电商数据分析——淘宝实战》一书接触零一的。在该书中，他用相当多的实务案例来告诉读者如何在电商的环境中，用数据做决策，从实践中学知识，令我印象深刻。后来通过 CDA 的活动认识了零一，发现他是一名数据分析爱好者。在跟他的谈话中，提到的更多的是实务的应用，令我钦佩不已。

人工智能的先驱者吴恩达曾说过，一家人工智能的公司必须具备三种能力：其一是有策略的数据采集，其二是集中式的数据仓库及统一的数据分析平台，最后是无所不在的自动化应用。零一的这本书就是教你如何系统化地采集数据、储存数据及应用数据。

这本书教大家如何利用 Python 撰写爬虫程序、清洗和组织数据、解析网页的内容，并将数据储存于数据库中。本书巨细无遗，帮助大家节省时间，是值得一读的好书！

李御玺（Yue-Shi Lee）

台湾大学资讯工程博士

铭传大学资讯工程学系教授

前　言

Python 是军刀型的开源工具，被广泛应用于 Web 开发、爬虫、数据清洗、自然语言处理、机器学习和人工智能等方面，而且 Python 的语法简洁易读，这让许多编程入门者不再望而却步，因此 Python 在最近几年非常受欢迎，各行各业的技术人员都开始使用 Python。

本书内容来自笔者在高校授课的内容，主要介绍如何运用 Python 工具获取电商平台的页面数据，并对数据进行清洗和存储。本书简化了 Python 基础部分，保证有足够的篇幅来介绍爬虫和数据清洗的内容。

本书采用的版本是 Python 3.6.2，是笔者写书时的最新版本，而且笔者习惯用的操作平台是 Windows 系统。虽然目前一些高校和开发者在使用 Python 2.7，但是 Python 团队将在 2020 年停止对 Python 2.7 的支持更新，Python 2.X 转向 Python 3.X 是大势所趋。

本书第 1 章简单介绍 Python 和相关的 IDE，如果读者完全没有 Python 基础，那么建议选购一本基础书作为辅助。第 2 ~ 6 章介绍爬虫的实例，实现从最简单的爬虫到相对比较复杂的爬虫。鉴于实例的限制，本书的爬虫内容没有涉及代理服务器和验证码处理等问题。第 7 章介绍在 Python 中如何连接并操作数据库。第 8 章介绍了 NumPy 及其用法。第 9 章详细介绍 pandas 的功能，pandas 是 Python 数据清洗和建模中非常重要的库。第 10 章用两个完整案例展示了从爬虫到建模的过程。第 11 章介绍 Python 的可视化，选用的库是 matplotlib 和 pyecharts，这里详细介绍了 pyecharts。

鉴于作者的水平有限，不足之处请读者不吝指教。

轻松注册成为博文视点社区用户（www.broadview.com.cn），扫码直达本书页面。

- **下载资源**：本书如提供示例代码及资源文件，均可在 下载资源 处下载。
- **提交勘误**：您对书中内容的修改意见可在 提交勘误 处提交，若被采纳，将获赠博文视点社区积分（在您购买电子书时，积分可用来抵扣相应金额）。
- **交流互动**：在页面下方 读者评论 处留下您的疑问或观点，与我们和其他读者一同学习交流。

页面入口：*http://www.broadview.com.cn/33359*

目　录

第 1 章　Python 基础 1

1.1　安装 Python 环境 1
1.1.1　Python 3.6.2 安装与配置 1
1.1.2　使用 IDE 工具——PyCharm 4
1.1.3　使用 IDE 工具——Anaconda 4
1.2　Python 操作入门 6
1.2.1　编写第一个 Python 代码 6
1.2.2　Python 基本操作 9
1.2.3　变量 10
1.3　Python 数据类型 10
1.3.1　数字 10
1.3.2　字符串 11
1.3.3　列表 13
1.3.4　元组 14
1.3.5　集合 15
1.3.6　字典 15
1.4　Python 语句与函数 16
1.4.1　条件语句 16
1.4.2　循环语句 16
1.4.3　函数 17

第 2 章　写一个简单的爬虫 18

2.1　关于爬虫的合法性 18
2.2　了解网页 20
2.2.1　认识网页结构 21
2.2.2　写一个简单的 HTML 21
2.3　使用 requests 库请求网站 23

2.3.1 安装 requests 库 23
2.3.2 爬虫的基本原理 25
2.3.3 使用 GET 方式抓取数据 26
2.3.4 使用 POST 方式抓取数据 27
2.4 使用 Beautiful Soup 解析网页 30
2.5 清洗和组织数据 34
2.6 爬虫攻防战 35
第 3 章 用 API 爬取天气预报数据 38
3.1 注册免费 API 和阅读技术文档 38
3.2 获取 API 数据 40
3.3 存储数据到 MongoDB 45
3.3.1 下载并安装 MongoDB 45
3.3.2 在 PyCharm 中安装 Mongo Plugin 46
3.3.3 将数据存入 MongoDB 49
3.4 MongoDB 数据库查询 52
第 4 章 大型爬虫案例：抓取某电商网站的商品数据 55
4.1 观察页面特征和解析数据 55
4.2 工作流程分析 64
4.3 构建类目树 65
4.4 获取产品列表 68
4.5 代码优化 70
4.6 爬虫效率优化 74
4.7 容错处理 77
第 5 章 Scrapy 爬虫 78
5.1 Scrapy 简介 78
5.2 Scrapy 安装 79
5.3 案例：用 Scrapy 抓取股票行情 80
第 6 章 Selenium 爬虫 88
6.1 Selenium 简介 88
6.2 案例：用 Selenium 抓取电商网站数据 90

第 7 章 数据库连接和查询 100
7.1 使用 PyMySQL 100
7.1.1 连接数据库 100
7.1.2 案例：某电商网站女装行业 TOP100 销量数据 102
7.2 使用 SQLAlchemy 104
7.2.1 SQLAlchemy 基本介绍 104
7.2.2 SQLAlchemy 基本语法 105
7.3 MongoDB 107
7.3.1 MongoDB 基本语法 107
7.3.2 案例：在某电商网站搜索“连衣裙”的商品数据 107
第 8 章 NumPy 109
8.1 NumPy 简介 109
8.2 一维数组 110
8.2.1 数组与列表的异同 110
8.2.2 数组的创建 111
8.3 多维数组 111
8.3.1 多维数组的高效性能 112
8.3.2 多维数组的索引与切片 113
8.3.3 多维数组的属性 113
8.4 数组的运算 115
第 9 章 pandas 数据清洗 117
9.1 数据读写、选择、整理和描述 117
9.1.1 从 CSV 中读取数据 119
9.1.2 向 CSV 写入数据 120
9.1.3 数据选择 120
9.1.4 数据整理 122
9.1.5 数据描述 123
9.2 数据分组、分割、合并和变形 124
9.2.1 数据分组 124
9.2.2 数据分割 127
9.2.3 数据合并 128
9.2.4 数据变形 134
9.2.5 案例：旅游数据的分析与变形 136

9.3 缺失值、异常值和重复值处理 140
9.3.1 缺失值处理 140
9.3.2 检测和过滤异常值 144
9.3.3 移除重复数据 147
9.3.4 案例：旅游数据的值检查与处理 149
9.4 时序数据处理 152
9.4.1 日期/时间数据转换 152
9.4.2 时序数据基础操作 153
9.4.3 案例：天气数据分析与处理 155
9.5 数据类型转换 158
9.6 正则表达式 160
9.6.1 元字符与限定符 161
9.6.2 案例：用正则表达式提取网页文本信息 162
第 10 章 综合应用实例 164
10.1 按性价比给用户推荐旅游产品 164
10.1.1 数据采集 165
10.1.2 数据清洗、建模 169
10.2 通过热力图分析为用户提供出行建议 172
10.2.1 某旅游网站热门景点爬虫代码（qunaer_sights.py） 175
10.2.2 提取 CSV 文件中经纬度和销量信息 178
10.2.3 创建景点门票销量热力地图 HTML 文件 179
第 11 章 数据可视化 182
11.1 matplotlib 183
11.1.1 画出各省份平均价格、各省份平均成交量柱状图 183
11.1.2 画出各省份平均成交量折线图、柱状图、箱形图和饼图 184
11.1.3 画出价格与成交量的散点图 185
11.2 pyecharts 186
11.2.1 Echarts 简介 186
11.2.2 pyecharts 简介 187
11.2.3 初识 pyecharts，玫瑰相送 187
11.2.4 pyecharts 基本语法 188
11.2.5 基于商业分析的 pyecharts 图表绘制 190
11.2.6 使用 pyecharts 绘制其他图表 199
11.2.7 pyecharts 和 Jupyter 203

第 1 章

Python 基础

1.1 安装 Python 环境

1.1.1 Python 3.6.2 安装与配置

根据 Windows 版本（64 位/32 位）从 Python 官网安装下载对应的版本，如图 1-1 所示。

官方下载网址：https://www.python.org/

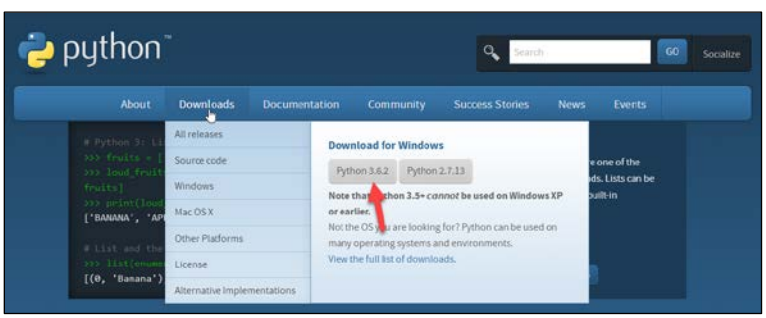

图 1-1

下载完成后，双击文件以运行安装程序安装 Python，如图 1-2 所示。

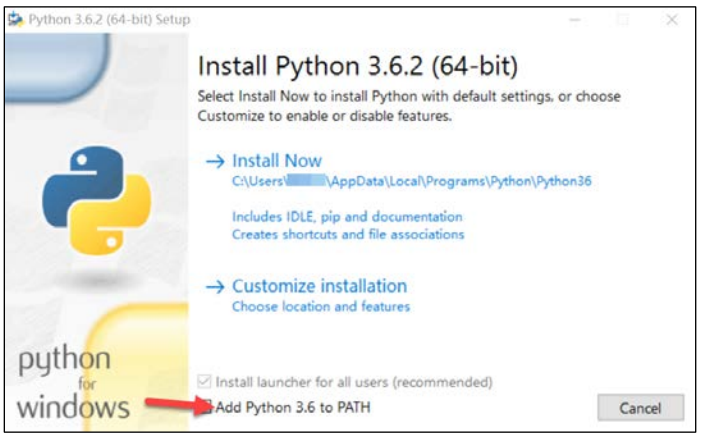

图 1-2

STEP 1：勾选“Add Python 3.6 to PATH”选项后单击“Customize installation”选项。

这个选项用于将 Python 3.6 加入系统路径，勾选该选项会使日后的操作非常方便；如果没有勾选这个选项就需要手动为系统的环境变量添加路径。

STEP 2：在弹出的选项卡中勾选所有的选项，并单击“Next”按钮，如图 1-3 所示。

选项“Documentation”表示安装 Python 的帮助文档；选项“pip”表示安装 Python 的第三方包管理工具；选项“tcl/tk and IDLE”表示安装 Python 的集成开发环境；选项“Python test suite ”表示安装 Python 的标准测试套件，后两个选项则表示允许版本更新。

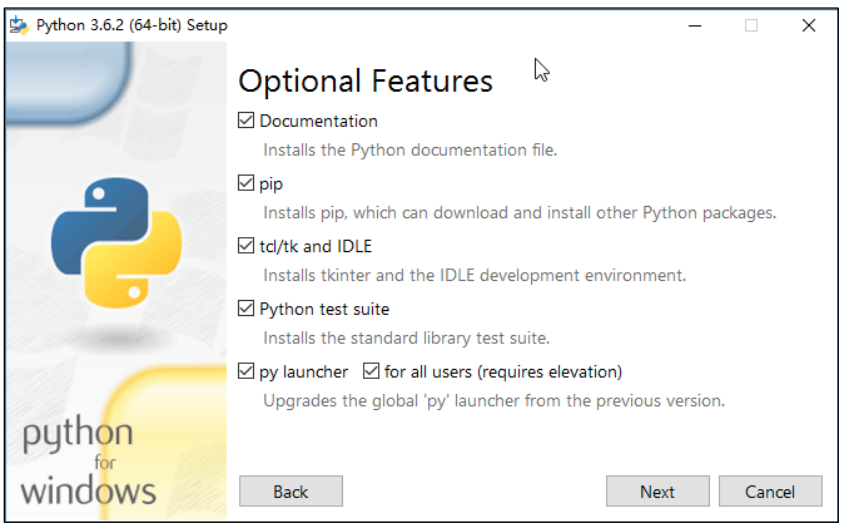

图 1-3

STEP3：保持默认勾选状态，单击“Browse”按钮，选择安装路径，如图 1-4 所示。

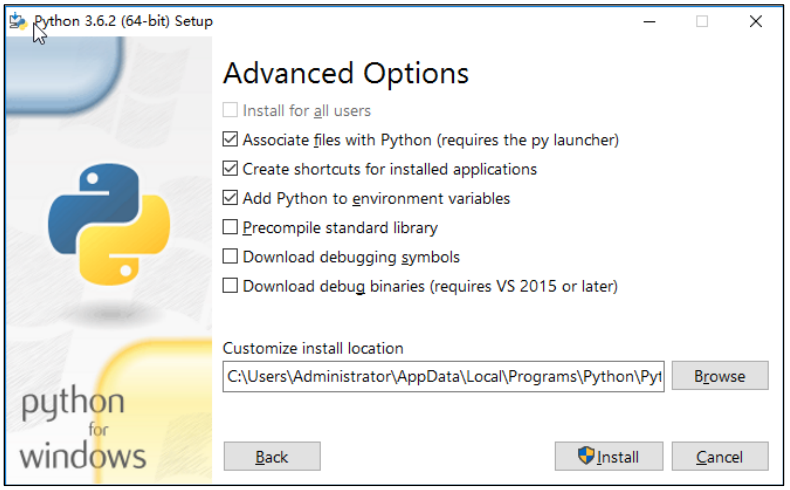

图 1-4

STEP4：单击“Install”按钮，直至完成安装。

安装好后，调出命令提示符，输入“python”，检查是否安装成功。如果 Python 安装成功，将出现如图 1-5 所示的界面，即输入“python”后，会看到“>>>”符号。

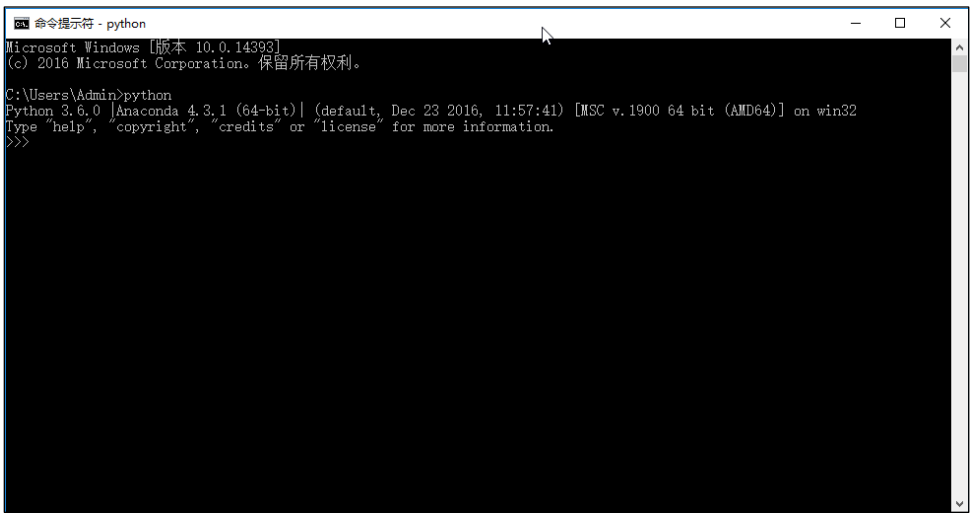

图 1-5

1.1.2 使用 IDE 工具——PyCharm

安装好环境后，还需要配置一个程序员专属工具，即 PyCharm，它是一个适合用于开发的多功能 IDE（集成开发环境），下载社区版（免费版）。

笔者使用的版本是 2017.2.2，发行日期是 2017 年 8 月 24 日，下载地址如下（参见图 1-6）。

http://www.jetbrains.com/pycharm/download/#section=windows

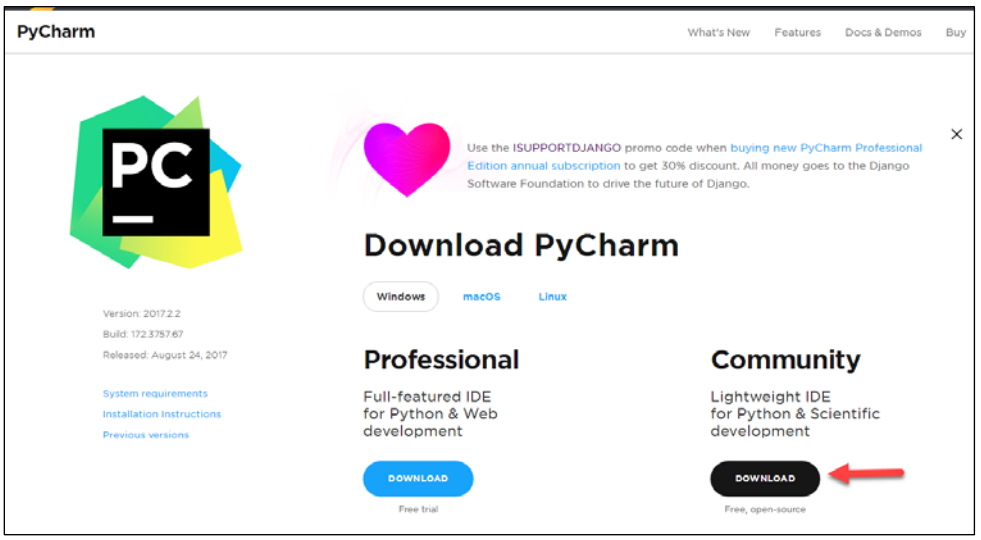

图 1-6

PyCharm 非常好用，通过 PyCharm 可以下载、安装和管理库。

1.1.3 使用 IDE 工具——Anaconda

Anaconda 是一个专门用于统计和机器学习的 IDE，它集成了 Python 和许多基础的库，如果业务场景是统计和机器学习，那么只要安装一个 Anaconda 就可以了，这样省去许多复杂的配置过程。

Anaconda 的官方下载地址如下（参见图 1-7）。

https://www.anaconda.com/download/

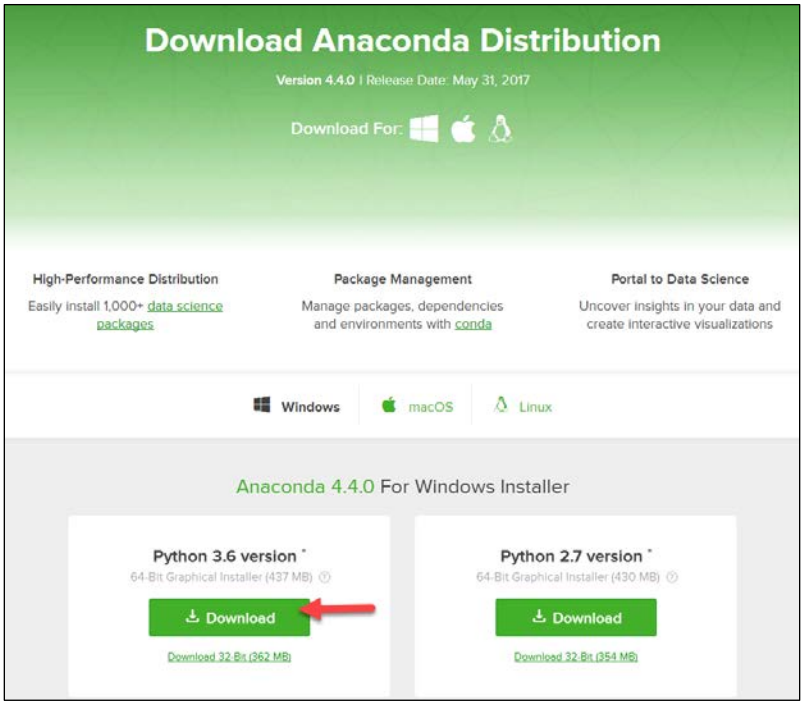

图 1-7

这里默认下载的是 64 位的版本，如果需要 32 位的版本，那么可以单击“Download”按钮下的文字链接。

使用 Anaconda 不需要提前安装 Python，安装后即可运行：通过快捷键【Win+R】调用运行窗口，输入“ipython jupyter”，然后单击“确定”按钮（参见图 1-8）。

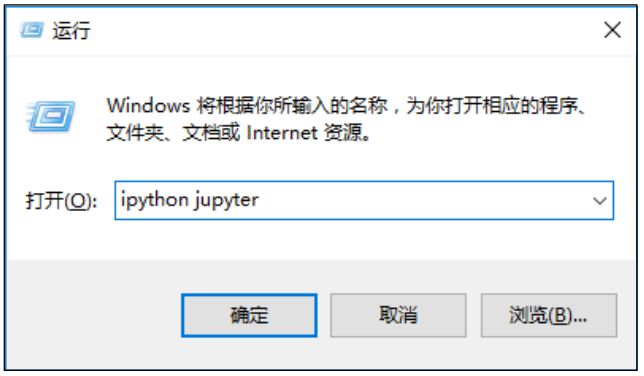

图 1-8

1.2 Python 操作入门

1.2.1 编写第一个 Python 代码

运行 PyCharm 后，需要先新建计划，单击“Create New Project”选项（参见图 1-9）。

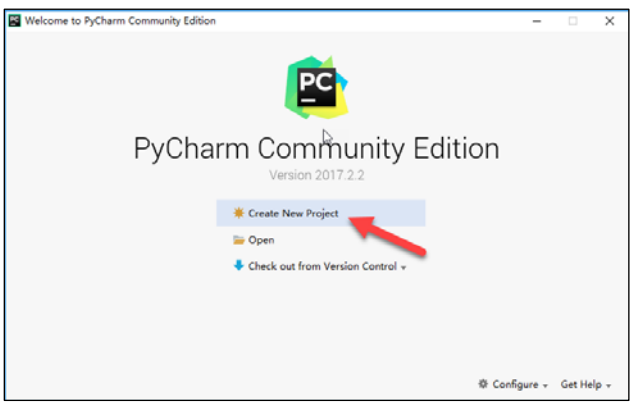

图 1-9

设置 Location（路径）和 Interpreter（翻译器），笔者同时安装了 Python 和 Anaconda，所以图 1-10 中的翻译器有两个可选项，二者的区别在于 Anaconda 中有许多预置好的库，不用再配置库了。这里选择 Python 原版的翻译器，然后单击右下角的“Create”按钮。

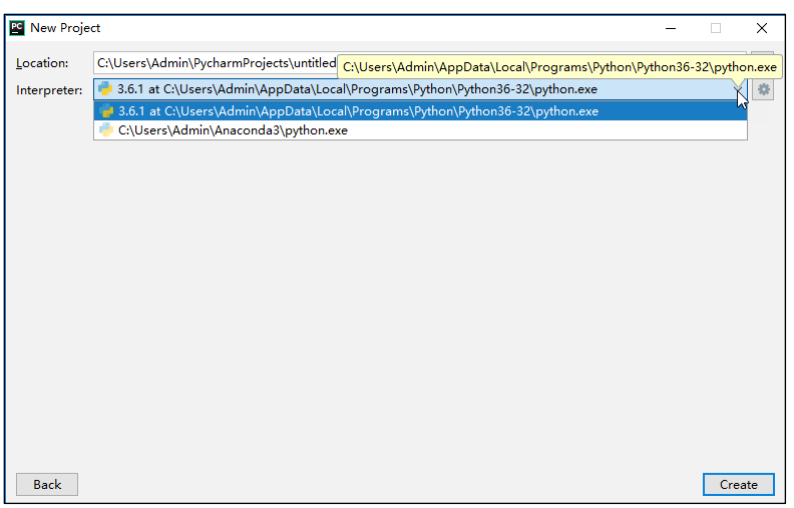

图 1-10

新建 Project（计划）后，在左侧的项目窗口，右击鼠标，在快捷菜单中选择“New”→“Python File”命令，新建 Python 文件（参见图 1-11）。

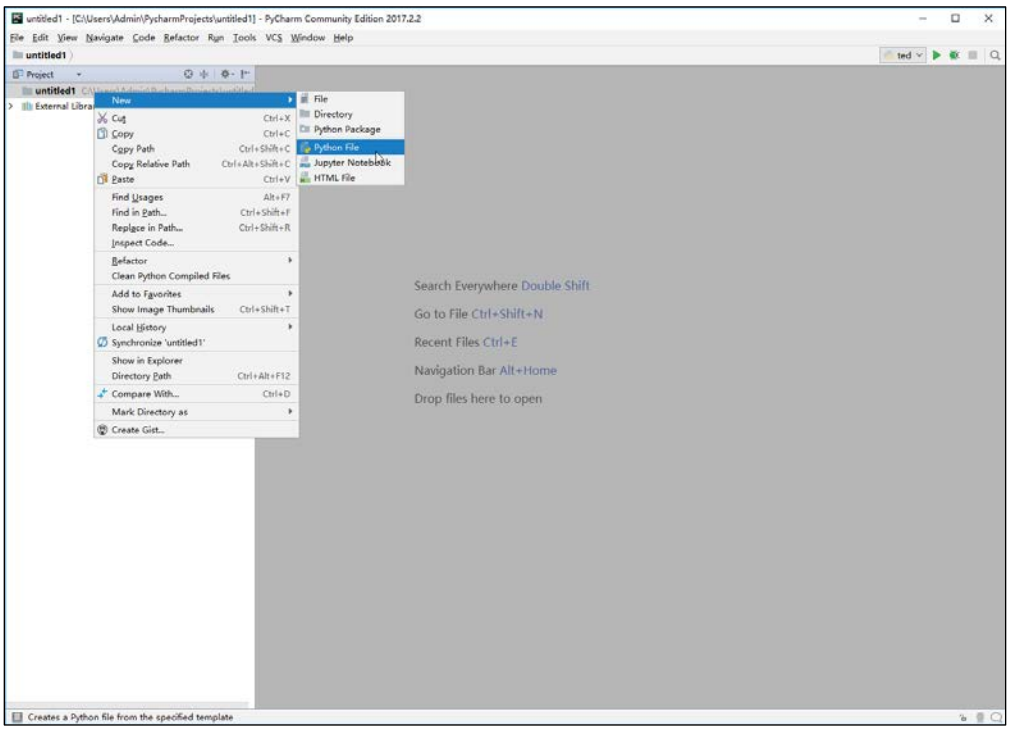

图 1-11

设置 Name（文件名），然后单击右下角的“OK”按钮（参见图 1-12）。

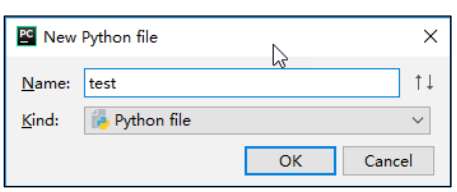

图 1-12

新建文件后，右侧的空白区域就是代码编辑区（参见图 1-13）。

从“Hello World（你好，世界）”开始吧！在编辑区中输入print('Hello, World!')，print()是一个打印函数，表示将括号中的文本打印在即时窗口中。

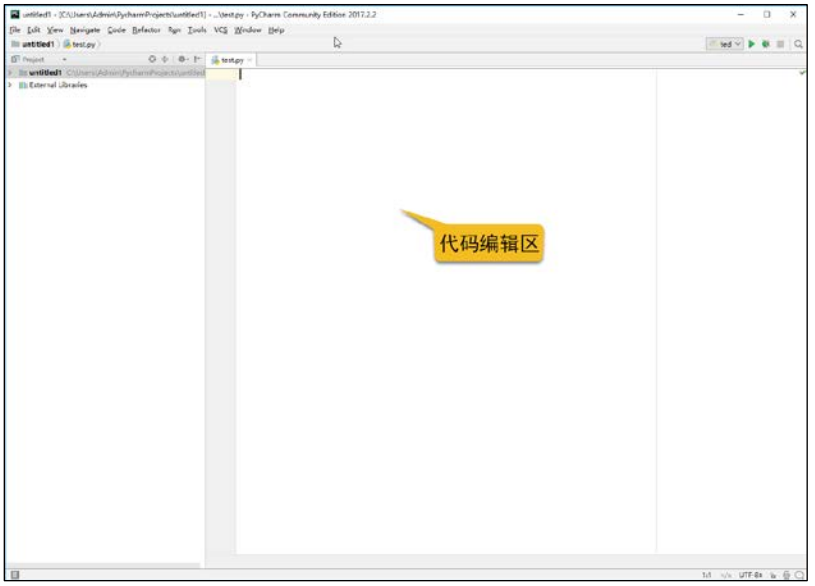

图 1-13

然后将鼠标光标停留在括号右侧，右击鼠标，在快捷菜单中选择“Run ‘test’”命令，其中单引号中的 test 是当前的文件名，一定要注意运行的文件名和要运行的文件名保持一致。运行后可以观察到即时窗口中打印出“Hello，World!”，如图 1-14 所示。

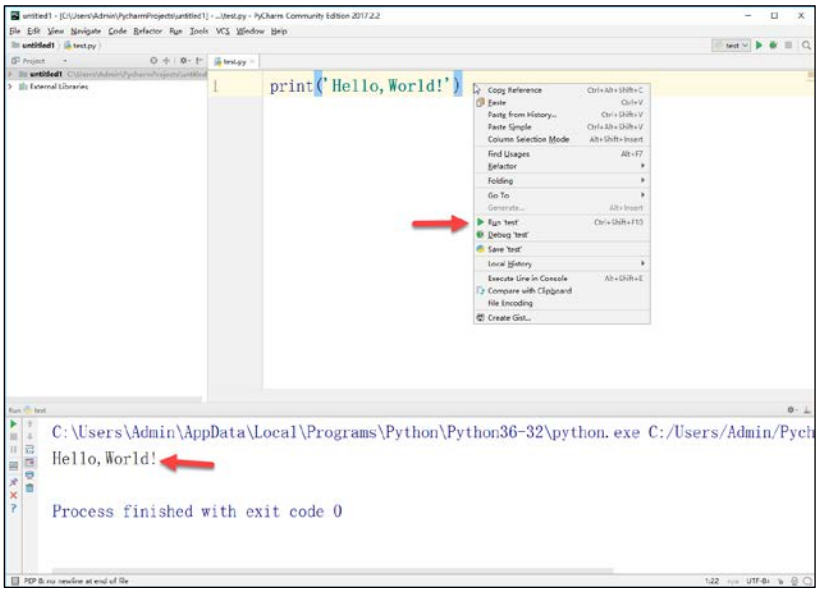

图 1-14

1.2.2　Python 基本操作

1．Python 注释

注释的目的是让阅读人员能够轻松读懂每一行代码的意义，同时也为后期代码维护提供便利。在 Python 中，单行注释以#号开头，如下所示。

```
#第一个注释
print('Hello,Wold!')#第二个注释
```

Python 的多行注释用两个三引号'''包含起来，如下所示。

```
'''
第一行注释
第二行注释
'''
print('Hello,World!')
```

2．Python 的行与缩进

Python 最具特色的就是使用缩进来表示代码块，不需要使用大括号。缩进的空格数是可变的，但是同一个代码块的语句必须包含相同的缩进空格数，缩进不一致会导致代码运行错误。

正确缩进的示例如下。

```
if True:
    print("True")
else:
    print("False")
```

错误缩进的示例如下。

```
if True:
    print("True")
else:
print("False")
```

3．多行语句

Python 通常是一行写完一条语句，但语句很长的话，可以通过反斜杠（\）来实现多行语句。

```
weekdays="Little Robert asked his mother for two cents.\
 'What did you do with the money I gave you yesterday?'"
print(weekdays)
```

这里的输出结果为“Little Robert asked his mother for two cents. 'What did you do with the money I gave you yesterday?'”。

4．等待用户输入

Python 中的 input()函数是用来与用户进行交互的，如下所示。

```
print("Who are you?")
you=input()
print("Hello!")
print(you)
```

此时，运行结果为“Who are you?”。

当用户输入 Lingyi，然后按【Enter】键时，程序会继续运行，其输出结果如下。

```
Hello!
Lingyi
```

1.2.3 变量

1．变量赋值

在编辑区输入以下代码。

```
a = 42
print(a)
```

注意：Python 的变量无须提前声明，赋值的同时也就声明了变量。

2．变量命名

Python 中具有自带的关键字（保留字），任何变量名不能与之相同。在 Python 的标准库中提供了一个 keyword 模块，可以查阅当前版本的所有关键字，如下所示。

```
import keyword
keyword.kwlist
```

1.3 Python 数据类型

Python 中拥有 6 大数据类型：number（数字）、string（字符串）、list（列表）、tuple（元组）、sets（集合）、dictionary（字典）。

1.3.1 数字

（1）数字类型

Python 3 支持 4 种类型的数字：int（整数类型）、float（浮点类型）、bool（布尔类型）、complex（复数类型）。在 Python3 中可以使用 type()函数来查看数字类型，如下所示。

a=1	b=3.14	c=True
print(type(a))	print(type(b))	print(type(c))
输出结果<class 'int'>	输出结果<class 'float'>	输出结果 <class 'bool'>

（2）Python3 所支持的运算类型包括加法、减法、除法、整除、取余、乘法和乘方。

```
print((3+1))    #加法运算，输出结果为 4
print((8.4-3)) #减法运算，输出结果为 5.4
print(15/4)     #除法运算，输出结果为 3.75
print(15//4)    #整除运算，输出结果为 3
print(15%4)     #取余运算，输出结果为 3
print(2*3)      #乘法运算，输出结果为 6
print(2**3)     #乘方运算，输出结果为 8
```

1.3.2　字符串

1．字符类型

字符串就是在单引号、双引号和三引号之间的文字。单引号示例：print('welcome to hangzhou')，其中所有的空格和制表符都照原样保留。单引号与双引号的作用其实是一样的，但是当引号里包含单引号时，则该引号需使用双引号，例如：print("what’s your name?")。三引号可以指示一个多行的字符串，也可以在三引号中自由使用单引号和双引号，如下所示。

```
print('''Mike:Hi,How are you?
LiMing:Fine,Thank you!and you?
Mike:I'm fine, too! ''')
```

2．字符串的表示方式

如果要在单引号字符串中使用单引号本身，在双引号字符串中使用双引号本身，则需要借助于转义符（\），如下所示。

```
print('what\'s your name?')
```

输出结果如下。

```
what's your name?
```

注意：在一个字符串中，行末单独的斜杠号表示下一行继续，而不是开始写新的一行（详见 1.2.2 节），另外可以使用双反斜杠（\\）来表示反斜杠本身，而\n 表示换行符。

如果想要指示某些不需要使用转义符进行特别处理的字符串，那么需要指定一个原始字符串。原始字符串通过给字符串加上前缀 r 或 R 的方式指定，比如需要原样输出\n 而不是令其换行，则代码如下。

```
print(r"Newlines are indicated by \n")
```

输出结果如下。

```
Newlines are indicated by \n
```

3．字符串的截取

字符串的截取格式如下所示。

```
字符串变量[start_index:end_index+1]
```

此处解释下为什么加 1：字符串的截取从 start_index 开始，到 end_index 结束，也就是大家常理解的左闭右开，如下所示。

```
str='Lingyi'
print(str[0])   #输出结果为 L
print(str[1:4]) #输出结果为 ing
print(str[-1])  #输出结果为 i
```

4．字符运算

尝试下面的代码：

```
num=1
string='1'
print(num+string)
```

此时，运行程序会报错，错误提示如下所示，为什么呢?

```
TypeError: unsupported operand type(s) for +: 'int' and 'str'
```

字符串（string）只是 Python 中的一种数据类型，下面的语句在赋值的时候右侧用了单引号，数据类型是字符串（string）。

```
string='1'
```

下面语句的数据类型为整型（integer）。

```
num=1
```

不同的数据类型之间是不能进行运算的，但是，不同数据类型可以相互转换，以上代码通过修改后就可以正常运行，修改后的代码如下。

```
num=1
string='1'
num2=int(string)
print(num+num2)
```

注意：“+”号用在字符串中间是连接符，用在数值中间是运算符：int()是将括号中的数值或者文本转换成整型数据类型。

运行后，即时窗口中打印的结果是 2，如图 1-15 所示。

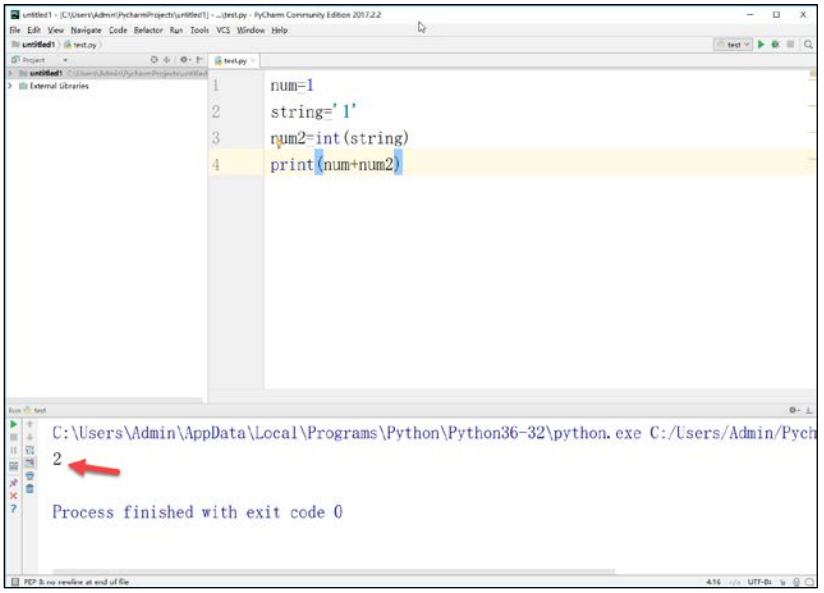

图 1-15

四则基础运算如下。

```
a=1
b=2
c=a+b
print(c)
```

因为相加的双方是数值型，此时“+”号是运算符，运行结果如下。

```
3
```

相加的双方是字符型数据，此时“+”号是连接符。

```
a=1
b=2
c='a'+'b'
print(c)
```

运行结果如下。

```
ab
```

1.3.3　列表

（1）列表格式

Python 列表是任意对象的有序集合，列表写在中括号[]里，元素之间用逗号隔开。这里的任意对

象，既可以是列表嵌套列表，也可以是字符串，如下所示。

```
list=["Python",12,[1,2,3],3.14,True]
print(list)#运行结果为['Python', 12, [1, 2, 3], 3.14, True]
```

（2）列表的切片

每个 list（list 是笔者自定义的变量）中的元素从 0 开始计数，如下代码可以选取 list 中的第一个元素。

```
list=[1,2,3,4]
print(list[0])
```

运行结果如下。

```
1
```

列表删除操作可以使用 remove 方法，只需要在变量名字后面加个句号就可以轻松调用，PyCharm 有自动联想功能，选中目标方法或者函数，按【Tab】键即可快速键入，如图 1-16 所示。

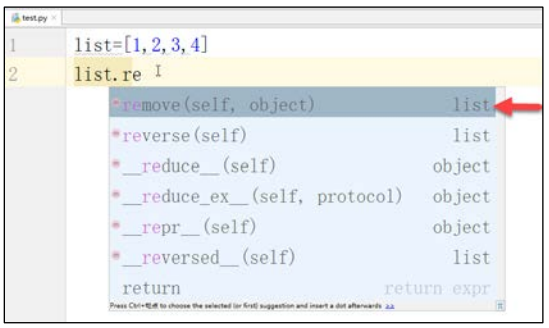

图 1-16

以下代码用于删除第 3 个元素，并用 print 将结果打印出来。其中 remove 方法用于删除列表的元素。

```
list.remove(3)
print(list) # 运行结果是[1, 2, 4]
```

1.3.4 元组

元组（tuple）与列表类似，不同之处在于元组的元素不能修改。元组写在小括号()里，元素之间则用逗号隔开，如下所示。

```
tuple=['abc',76,'ly',898,5.2]
print(tuple[1:3])
```

运行结果如下。

```
[76,'ly']
```

1.3.5　集合

集合（set）是一个无序不重复元素的序列，可以使用大括号{}或者 set()函数创建集合。需要注意的是，一个空集必须使用 set()函数创建而不能使用大括号{}，因为大括号{}是用来创建空字典的，如下所示。

```
age={18,19,18,20,21,20}
print(age)
```

运行结果如下。

```
{18,19,20,21}
```

1.3.6　字典

字典是一种可变容器模型，且可存储任意类型对象，用{}标识。字典是一个无序的键（key）值（value）对的集合，格式如下所示

```
dic = {key1 : value1, key2 : value2 }
```

接下来建立一个字典，代码如下。

```
information={
    'name':'liming',
    'age':'24'
}
print(information)
```

运行结果如下。

```
{'name': 'liming', 'age': '24'}
```

其中 name 是一个 key（键），liming 是一个 value（值）。
字典增加数据时，可以使用下面的方法。

```
information['sex']='boy'
print(information)
```

运行结果如下。

```
{'name': 'liming', 'age': '24', 'sex': 'boy'}
```

字典删除数据时，可以使用 del 函数，代码如下。

```
del information['age']
print(information)
```

运行结果如下。

```
{'name': 'liming', 'sex': 'boy'}
```

1.4 Python 语句与函数

1.4.1 条件语句

接下来进行登录验证操作，首先给变量 password 赋值，然后判断 password（密码）是否正确，正确就打印“login success!”（登录成功!），错误就打印“wrong password”（密码错误）。

```
password == '12345'
if password == '12345':
    print('login sucess!')
else:
    print('wrong password')
```

在 Python 中判断是否相等可以使用“==”两个等号（单个等号是赋值）。

条件语句的语法如下。

```
if 判断条件:
    执行语句……
else:
    执行语句……
```

1.4.2 循环语句

在 Python 中要注意缩进，条件语句根据缩进来判断执行语句的归属。

下面用 for 语句实现 1 至 9 的累加。

```
sum=0
for i in range(1,10,1):#不包含 10，实际为 1-9
    sum=i+sum
print(sum)
```

运行结果如下。

```
45
```

其中 range 表示范围，i 从 1（第 1 个参数）开始迭代，每次加 1（第 3 个参数），直到 i 变成了 10（第 2 个参数）结束，因此当 i=10 时不执行语句，for 循环是 9 次迭代。#号代表注释，#号后面的

文本将不会执行。在 PyCharm 中，如果要注释代码，则可以选中代码后按组合键【Ctrl+/】。

for 的语法如下。

```
for 迭代变量 in 迭代次数：
    执行语句……
```

如果是列表或者字典，就不用 range()函数，直接用列表或者字典，此时 i 表示列表或者字典中的元素，代码如下。

```
list=[1,2,3,4]
for i in list:
    print(i)
```

运行结果如下。

```
1
2
3
4
```

1.4.3　函数

在刚刚接触的函数中，print()是将结果打印出来的函数，int()是将字符串类型转换成数据类型的函数。类似这种函数，统称为内建函数，内建函数可以直接调用。

有内就有外，外建函数其实就是通常所讲的自定义函数。

自定义函数的语法如下。

```
def f(x):
    定义过程
    return f(x)
```

def（define 即定义）是创建函数的方法，下面用 def 创建方程：$y=5x+2$。

```
def y(x):
    y=5*x+2
    return y
# 下面调用自定义函数 y
d=y(5)
print(d)
```

运行结果如下

```
27
```

第 2 章

写一个简单的爬虫

2.1 关于爬虫的合法性

几乎每一个网站都有一个名为 robots.txt 的文档，当然也有部分网站没有设定 robots.txt。对于没有设定 robots.txt 的网站可以通过网络爬虫获取没有口令加密的数据，也就是该网站所有页面数据都可以爬取。如果网站有 robots.txt 文档，就要判断是否有禁止访客获取的数据。

以淘宝网为例，在浏览器中访问 https://www.taobao.com/robots.txt，如图 2-1 所示。淘宝网允许部分爬虫访问它的部分路径，而对于没有得到允许的用户，则全部禁止爬取，代码如下。

```
User-Agent:  *
Disallow:  /
```

这一句代码的意思是除前面指定的爬虫外，不允许其他爬虫爬取任何数据。

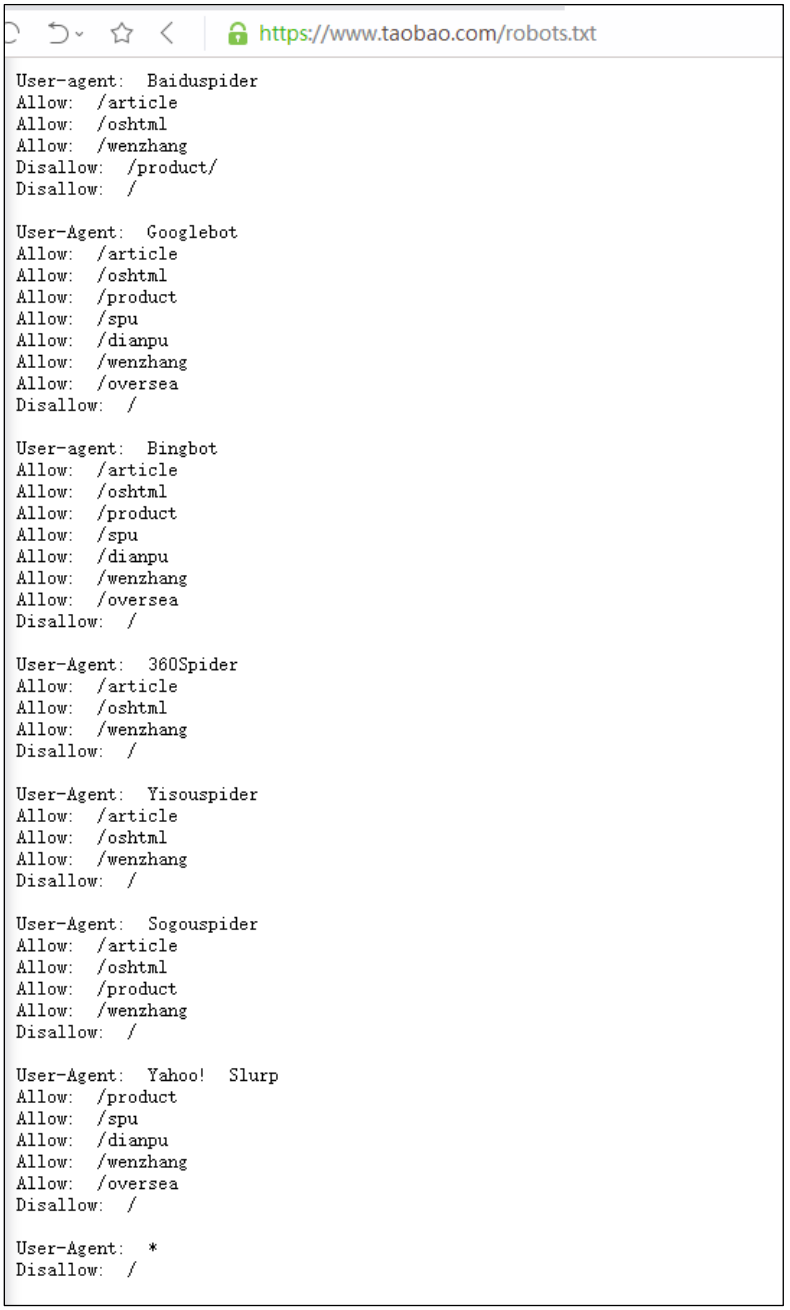
https://www.taobao.com/robots.txt
User-agent: Baiduspider
Allow: /article
Allow: /oshtml
Allow: /wenzhang
Disallow: /product/
Disallow: /
User-Agent: Googlebot
Allow: /article
Allow: /oshtml
Allow: /product
Allow: /spu
Allow: /dianpu
Allow: /wenzhang
Allow: /oversea
Disallow: /
User-agent: Bingbot
Allow: /article
Allow: /oshtml
Allow: /product
Allow: /spu
Allow: /dianpu
Allow: /wenzhang
Allow: /oversea
Disallow: /
User-Agent: 360Spider
Allow: /article
Allow: /oshtml
Allow: /wenzhang
Disallow: /
User-Agent: Yisouspider
Allow: /article
Allow: /oshtml
Allow: /wenzhang
Disallow: /
User-Agent: Sogouspider
Allow: /article
Allow: /oshtml
Allow: /product
Allow: /wenzhang
Disallow: /
User-Agent: Yahoo! Slurp
Allow: /product
Allow: /spu
Allow: /dianpu
Allow: /wenzhang
Allow: /oversea
Disallow: /
User-Agent: *
Disallow: /

图 2-1

2.2 了解网页

以中国旅游网首页（http://www.cntour.cn/）为例，如图 2-2 所示。抓取中国旅游网首页首条信息（标题和链接），数据以明文的形式出面在源码中。

图 2-2

在中国旅游网首页（http://www.cntour.cn/），按快捷键【Ctrl+U】打开源码页面，如图 2-3 所示。

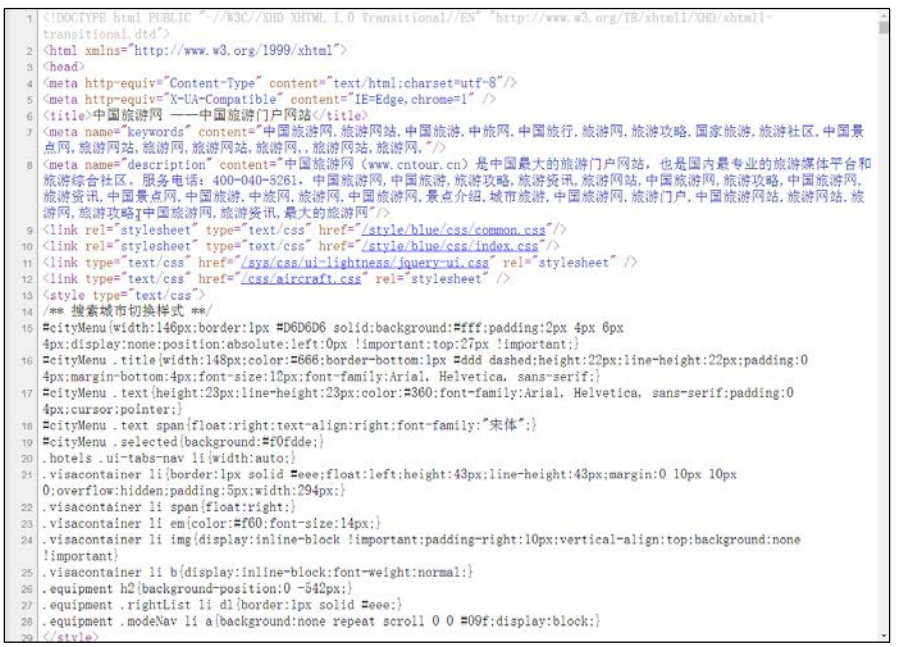

```
<!DOCTYPE html PUBLIC "-//W3C//XHD XHTML 1.0 Transitional//EN" "http://www.w3.org/TR/xhtml1/XHD/xhtml1-
transitional.dtd">
<html xmlns="http://www.w3.org/1999/xhtml">
<head>
<meta http-equiv="Content-Type" content="text/html;charset=utf-8"/>
<meta http-equiv="X-UA-Compatible" content="IE=Edge,chrome=1" />
<title>中国旅游网 ——中国旅游门户网站</title>
<meta name="keywords" content="中国旅游网,旅游网站,中国旅游,中旅网,中国旅行,旅游网,旅游攻略,国家旅游,旅游社区,中国景
点网,旅游网站,旅游网,旅游网站,旅游网,,旅游网站,旅游网,"/>
<meta name="description" content="中国旅游网（www.cntour.cn）是中国最大的旅游门户网站，也是国内最专业的旅游媒体平台和
旅游综合社区，服务电话：400-040-5261，中国旅游网,中国旅游,旅游攻略,旅游资讯,旅游网站,中国旅游网,旅游攻略,中国旅游网,
旅游资讯,中国景点网,中国旅游,中旅网,旅游网,中国旅游网,景点介绍,城市旅游,中国旅游网,旅游门户,中国旅游网站,旅游网站,旅
游网,旅游攻略I中国旅游网,旅游资讯,最大的旅游网"/>
<link rel="stylesheet" type="text/css" href="/style/blue/css/common.css"/>
<link rel="stylesheet" type="text/css" href="/style/blue/css/index.css"/>
<link type="text/css" href="/sys/css/ui-lightness/jquery-ui.css" rel="stylesheet" />
<link type="text/css" href="/css/aircraft.css" rel="stylesheet" />
<style type="text/css">
/** 搜索城市切换样式 **/
#cityMenu{width:146px;border:1px #D6D6D6 solid;background:#fff;padding:2px 4px 6px
4px;display:none;position:absolute;left:0px !important;top:27px !important;}
#cityMenu .title{width:148px;color:#666;border-bottom:1px #ddd dashed;height:22px;line-height:22px;padding:0
4px;margin-bottom:4px;font-size:12px;font-family:Arial, Helvetica, sans-serif;}
#cityMenu .text{height:23px;line-height:23px;color:#360;font-family:Arial, Helvetica, sans-serif;padding:0
4px;cursor:pointer;}
#cityMenu .text span{float:right;text-align:right;font-family:"宋体";}
#cityMenu .selected{background:#f0fdde;}
.hotels .ui-tabs-nav li{width:auto;}
.visacontainer li{border:1px solid #eee;float:left;height:43px;line-height:43px;margin:0 10px 10px
0;overflow:hidden;padding:5px;width:294px;}
.visacontainer li span{float:right;}
.visacontainer li em{color:#f60;font-size:14px;}
.visacontainer li img{display:inline-block !important;padding-right:10px;vertical-align:top;background:none
!important}
.visacontainer li b{display:inline-block;font-weight:normal;}
.equipment h2{background-position:0 -542px;}
.equipment .rightList li dl{border:1px solid #eee;}
.equipment .modeNav li a{background:none repeat scroll 0 0 #09f;display:block;}
</style>
```

图 2-3

2.2.1　认识网页结构

网页一般由三部分组成，分别是 HTML（超文本标记语言）、CSS（层叠样式表）和 JScript（活动脚本语言）。

1．HTML

HTML 是整个网页的结构，相当于整个网站的框架。带“<”、“>”符号的都是属于 HTML 的标签，并且标签都是成对出现的。

常见的标签如下。

```
<html>..</html>     表示标记中间的元素是网页
<body>..</body>     表示用户可见的内容
<div>.. </div>      表示框架
<p>..</p>           表示段落
<li>..</li>         表示列表
<img>..</img>       表示图片
<h1>..</h1>         表示标题
<a href="">..</a>   表示超链接
```

2．CSS

CSS 表示样式，图 2-3 中第 13 行<style type="text/css">表示下面引用一个 CSS，在 CSS 中定义了外观。

3．JScript

JScript 表示功能。交互的内容和各种特效都在 JScript 中，JScript 描述了网站中的各种功能。

如果用人体来比喻，HTML 是人的骨架，并且定义了人的嘴巴、眼睛、耳朵等要长在哪里。CSS 是人的外观细节，如嘴巴长什么样子，眼睛是双眼皮还是单眼皮，是大眼睛还是小眼睛，皮肤是黑色的还是白色的等。JScript 表示人的技能，例如跳舞、唱歌或者演奏乐器等。

2.2.2　写一个简单的 HTML

通过编写和修改 HTML，可以更好地理解 HTML。首先打开一个记事本，然后输入下面的内容。

```
<html>
<head>
    <title> Python3 爬虫与数据清洗入门与实战</title>
</head>
<body>
    <div>
        <p> Python3 爬虫与数据清洗入门与实战</p>
    </div>
    <div>
```

```
            <ul>
                <li><a href="http://www.baidu.com">爬虫</a></li>
                <li>数据清洗</li>
            </ul>
        </div>
    </body>
    </html>
```

输入代码后，保存记事本，然后按图 2-4 所示的方式修改文件名和后缀名。

图 2-4

运行该文件后的效果，如图 2-5 所示。

图 2-5

这段代码只是用到了 HTML，读者可以自行修改代码中的中文，然后观察其变化。

2.3 使用 requests 库请求网站

2.3.1 安装 requests 库

首先在 PyCharm 中安装 requests 库，为此打开 PyCharm，单击“File”（文件）菜单，选择“Default Settings”（默认设置）命令，如图 2-6 所示。

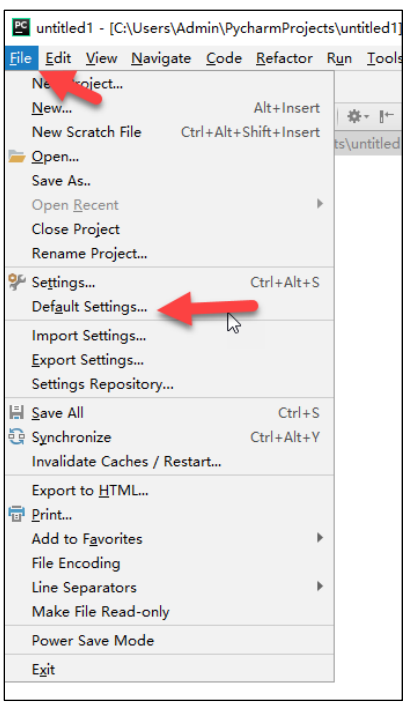

图 2-6

选择“Project Interpreter”（项目编译器）命令，确认当前选择的编译器，然后单击右上角的加号，如图 2-7 所示。

在搜索框输入：requests（注意，一定要输入完整，不然容易出错），勾选“Install to user’s site packages directory”（安装到用户的站点库目录）选项，如果不勾选该选项则会安装在临时目录中。然后单击左下角的“Install Package”（安装库）按钮。如图 2-8 所示。

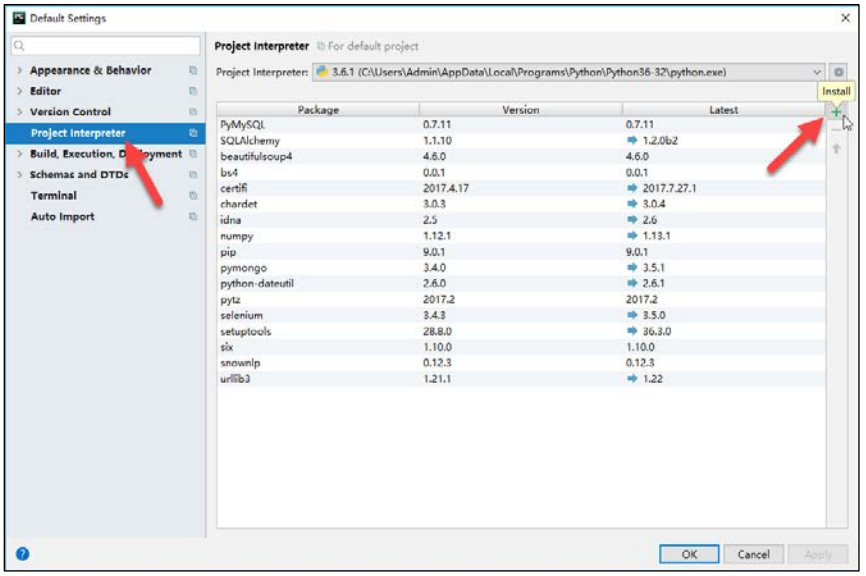
Default Settings
Project Interpreter
For default project
Appearance & Behavior
Editor
Version Control
Project Interpreter
Terminal
Auto Import
Project Interpreter: 3.6.1 (C:\Users\Admin\AppData\Local\Programs\Python\Python36-32\python.exe)
Install
Package
Version
Latest
PyMySQL 0.7.11 0.7.11
SQLAlchemy 1.1.10 1.2.0b2
beautifulsoup4 4.6.0 4.6.0
bs4 0.0.1 0.0.1
certifi 2017.4.17 2017.7.27.1
chardet 3.0.3 3.0.4
idna 2.5 2.6
numpy 1.12.1 1.13.1
pip 9.0.1 9.0.1
pymongo 3.4.0 3.5.1
python-dateutil 2.6.0 2.6.1
pytz 2017.2 2017.2
selenium 3.4.3 3.5.0
setuptools 28.8.0 36.3.0
six 1.10.0 1.10.0
snownlp 0.12.3 0.12.3
urllib3 1.21.1 1.22
OK
Cancel
Apply

图 2-7

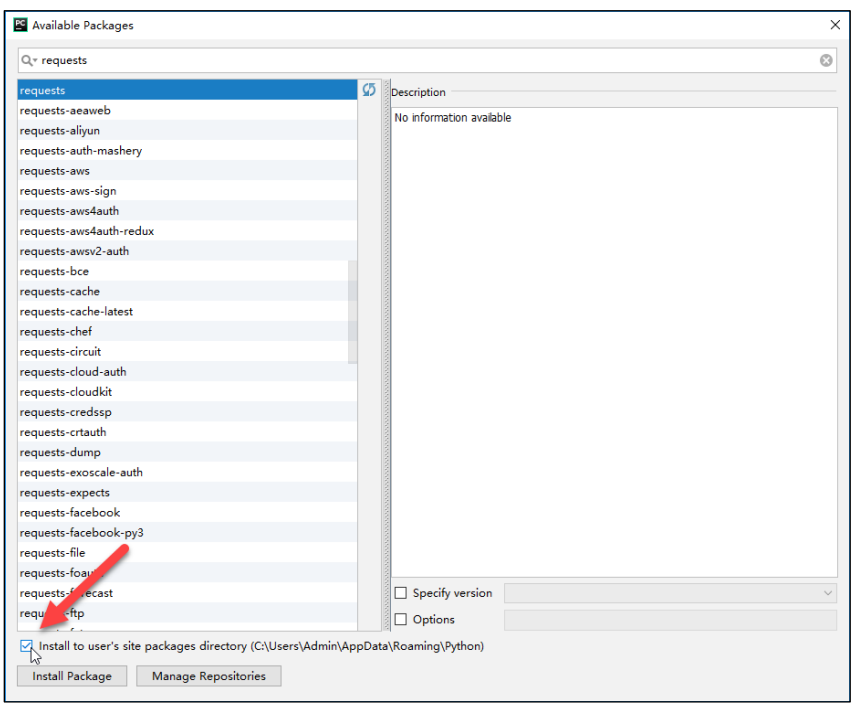
Available Packages
requests
requests
requests-aeaweb
requests-aliyun
requests-auth-mashery
requests-aws
requests-aws-sign
requests-aws4auth
requests-aws4auth-redux
requests-awsv2-auth
requests-bce
requests-cache
requests-cache-latest
requests-chef
requests-circuit
requests-cloud-auth
requests-cloudkit
requests-credssp
requests-crtauth
requests-dump
requests-exoscale-auth
requests-expects
requests-facebook
requests-facebook-py3
requests-file
Description
No information available
Specify version
Options
Install to user's site packages directory (C:\Users\Admin\AppData\Roaming\Python)
Install Package
Manage Repositories

图 2-8

安装完成后，会在 Install Package 上显示“Package ‘requests’ installed successfully”（库的请求已成功安装），如图 2-9 所示；如果安装不成功将会显示提示信息。

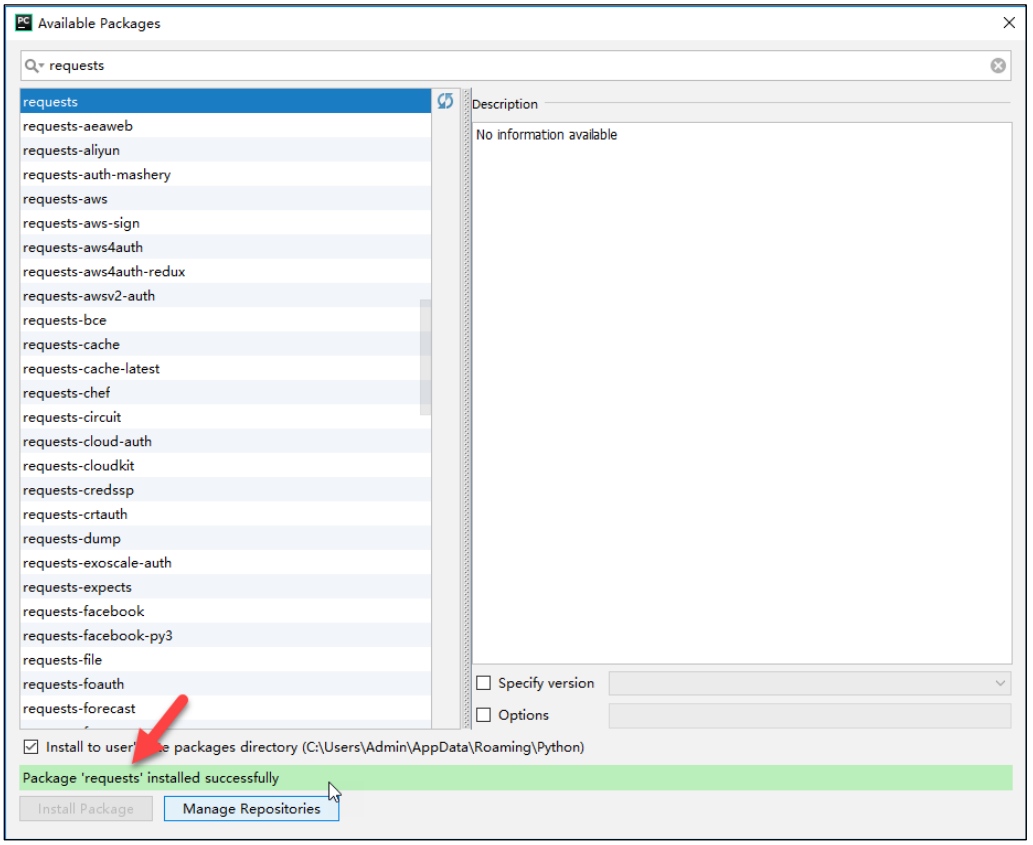

图 2-9

2.3.2　爬虫的基本原理

（1）网页请求的过程

- Request （请求）

每一个展示在用户面前的网页都必须经过这一步，也就是向服务器发送访问请求。

- Response（响应）

服务器在接收到用户的请求后，会验证请求的有效性，然后向用户（客户端）发送响应的内容，客户端接收服务器响应的内容，将内容展示出来，就是我们所熟悉的网页请求，如图 2-10 所示。

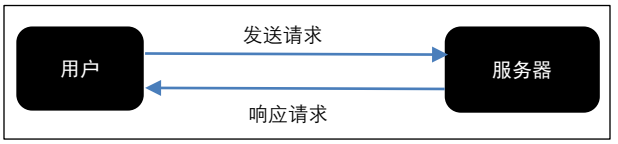

图 2-10

（2）网页请求的方式

GET：最常见的方式，一般用于获取或者查询资源信息，也是大多数网站使用的方式，响应速度快。

POST：相比 GET 方式，多了以表单形式上传参数的功能，因此除查询信息外，还可以修改信息。

所以，在写爬虫前要先确定向谁发送请求，用什么方式发送。

2.3.3 使用 GET 方式抓取数据

复制任意一条首页首条新闻的标题，在源码页面按【Ctrl+F】组合键调出搜索框，将标题粘贴在搜索框中，然后按【Enter】键。

如图 2-10 所示，标题可以在源码中搜索到，请求对象是 www.cntour.cn，请求方式是 GET（所有在源码中的数据请求方式都是 GET），如图 2-11 所示。

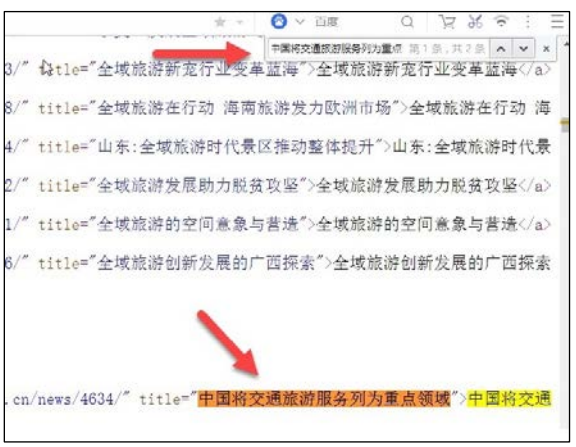

图 2-11

确定好请求对象和方式后，在 PyCharm 中输入以下代码。

```
import requests                          # 导入 requests 包
url='http://www.cntour.cn/'
strhtml=requests.get(url)                # GET 方式，获取网页数据
print(strhtml.text)
```

运行结果如图 2-12 所示。

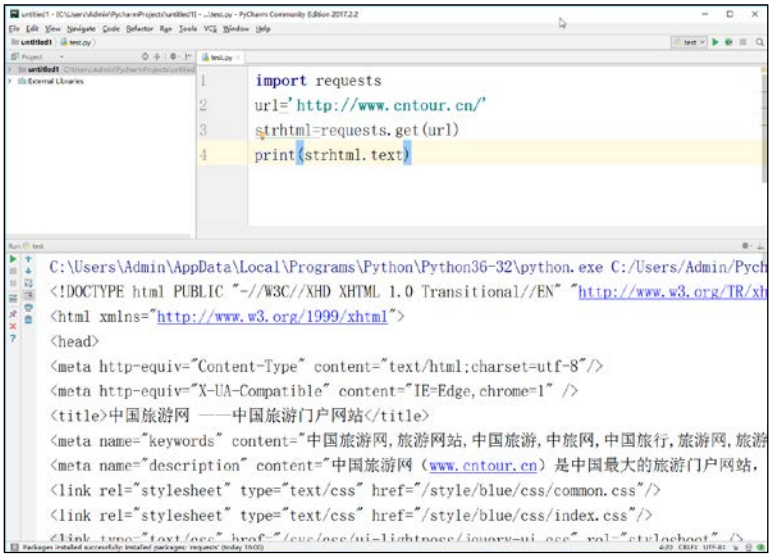

图 2-12

加载库使用的语句是 import+库的名字。在上述过程中，加载 requests 库的语句是：import requests。

用 GET 方式获取数据需要调用 requests 库中的 get 方法，使用方法是在 requests 后输入英文点号，如下所示。

```
requests.get
```

将获取到的数据存到 strhtml 变量中，代码如下。

```
strhtml=requests.get(url)
```

这个时候 strhtml 是一个 URL 对象，它代表整个网页，但此时只需要网页中的源码，下面的语句表示网页源码。

```
strhtml.text
```

2.3.4　使用 POST 方式抓取数据

首先输入有道翻译的网址：http://fanyi.youdao.com/，进入有道翻译页面。

按快捷键 F12，进入开发者模式，单击 Network，此时内容为空，如图 2-13 所示。

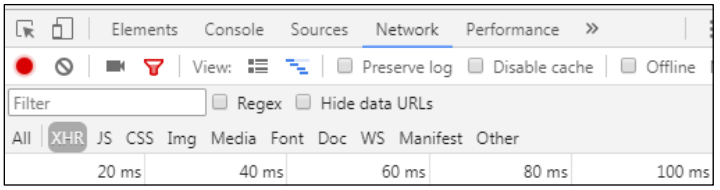

图 2-13

在有道翻译中输入“我爱中国”，单击“翻译”按钮，如图 2-14 所示。

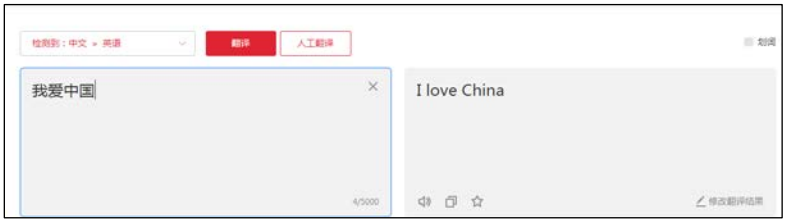

图 2-14

在开发者模式中，依次单击“Network”按钮和“XHR”按钮，找到翻译数据，如图 2-15 所示。

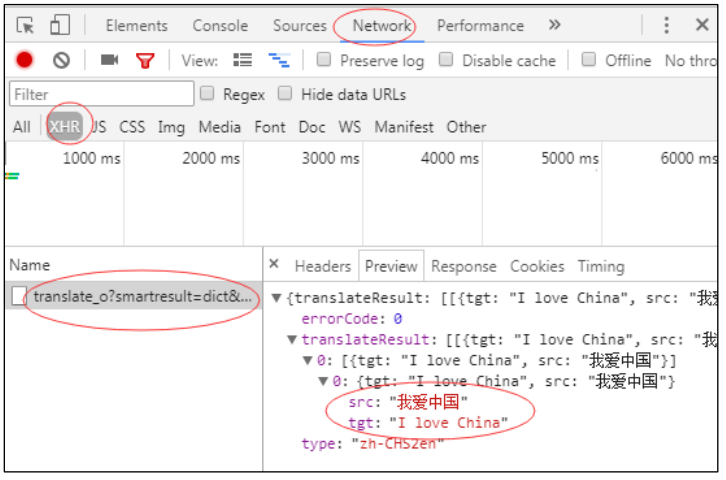

图 2-15

单击 Headers，发现请求数据的方式为 POST。如图 2-16 所示。

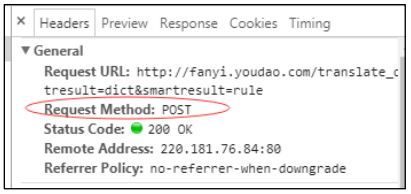

图 2-16

找到数据所在之处并且明确请求方式之后，接下来开始撰写爬虫。

首先，将 Headers 中的 URL 复制出来，并赋值给 url，代码如下。

```
    url = ' http://fanyi.youdao.com/translate?smartresult=dict&smartresult=rule'
```

POST 的请求获取数据的方式不同于 GET，POST 请求数据必须构建请求头才可以。Form Data 中的请求参数如图 2-17 所示，将其复制并构建一个新字典。

```
    Form_data= {'i': '我爱中国', 'from':'AUTO','to': 'AUTO','smartresult':
'dict', 'client':'fanyideskweb',
                'salt':'1512399450582','sign':' 78181ebbdcb38de9b4a3f4cd1d
38816b', 'doctype':'json',
                'version':'2.1','keyfrom':'fanyi.web',
                'action':'FY_BY_CLICKBUTTION','typoResult':'false'}
```

图 2-17

接下来使用 requests.post 方法请求表单数据，代码如下。

```
    import requests
    response = requests.post(url, data=payload)
```

将字符串格式的数据转换成 JSON 格式数据，并根据数据结构，提取数据，并将翻译结果打印出来，代码如下。

```
    import json
    content = json.loads(response.text)
    print(content['translateResult'][0][0]['tgt'])
```

使用 requests.post 方法抓取有道翻译结果的完整代码如下。

```
    import requests
    import json
    def get_translate_date(word=None):
        url='http://fanyi.youdao.com/translate?smartresult=dict&smartresult
=rule'
        Form_data = {'i':word, 'from':'AUTO','to': 'AUTO','smartresult': 'dict',
'client':'fanyideskweb',
                    'salt':'1512399450582','sign':'78181ebbdcb38de9b4a3f4cd1d3
8816b','doctype':'json',
                    'version': '2.1','keyfrom':'fanyi.web','action':'FY_BY_
CLICKBUTTION','typoResult':'false'}
        # 请求表单数据
        response = requests.post(url, data=payload)
        # 将 JSON 格式字符串转字典
        content = json.loads(response.text)
        # 打印翻译后的数据
        print(content['translateResult'][0][0]['tgt'])
    if __name__ == '__main__':
         get_translate_date('我爱数据')
```

2.4 使用 Beautiful Soup 解析网页

通过 requests 库已经可以抓到网页源码，接下来要从源码中找到并提取数据。Beautiful Soup 是 python 的一个库，其最主要的功能是从网页中抓取数据。Beautiful Soup 目前已经被移植到 bs4 库中，也就是说在导入 Beautiful Soup 时需要先安装 bs4 库。安装 bs4 库的方式如图 2-18 所示。

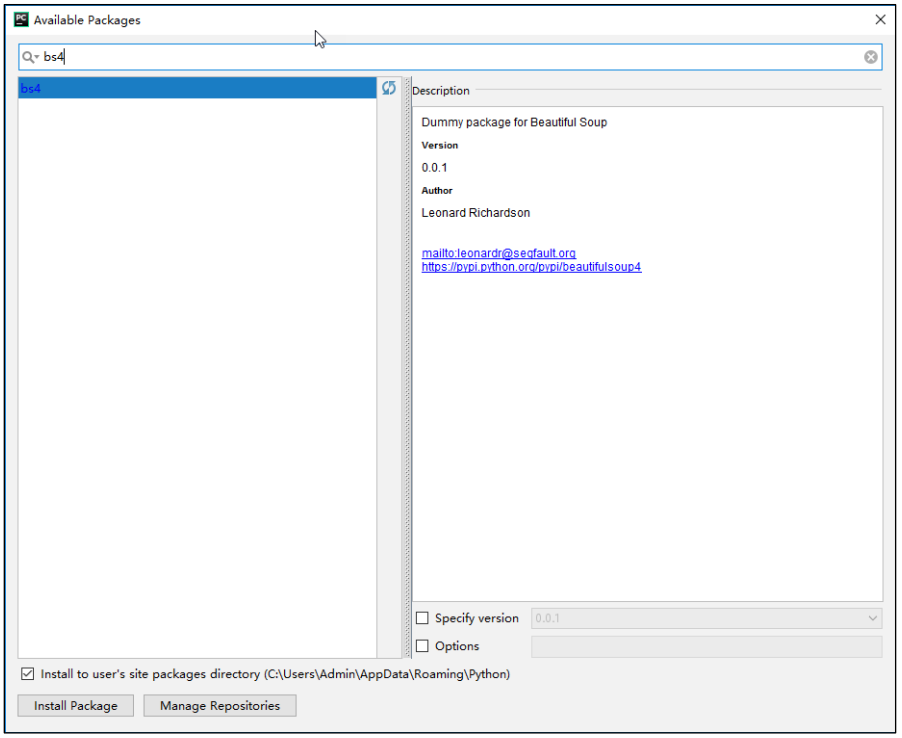

图 2-18

安装好 bs4 库以后，还需安装 lxml 库。如果我们不安装 lxml 库，就会使用 Python 默认的解析器。尽管 Beautiful Soup 既支持 Python 标准库中的 HTML 解析器又支持一些第三方解析器，但是 lxml 库具有功能更加强大、速度更快的特点，因此笔者推荐安装 lxml 库。安装 Python 第三方库后，输入下面的代码，即可开启 Beautiful Soup 之旅。

```
    from bs4 import  BeautifulSoup                  # 从 bs4 库中导入 Beautiful Soup

    ......

    soup=BeautifulSoup(strhtml.text,'lxml')     # lxml 解析网页文档
    data= soup.select('#main > div > div.mtop.firstMod.clearfix > div.centerBox >
ul.newsList > li > a')                          # 获取数据
    print(data)
```

代码运行结果如图 2-19 所示。

Beautiful Soup 库能够轻松解析网页信息，它被集成在 bs4 库中，需要时可以从 bs4 库中调用。其表达语句如下。

```
    from bs4 import  BeautifulSoup
```

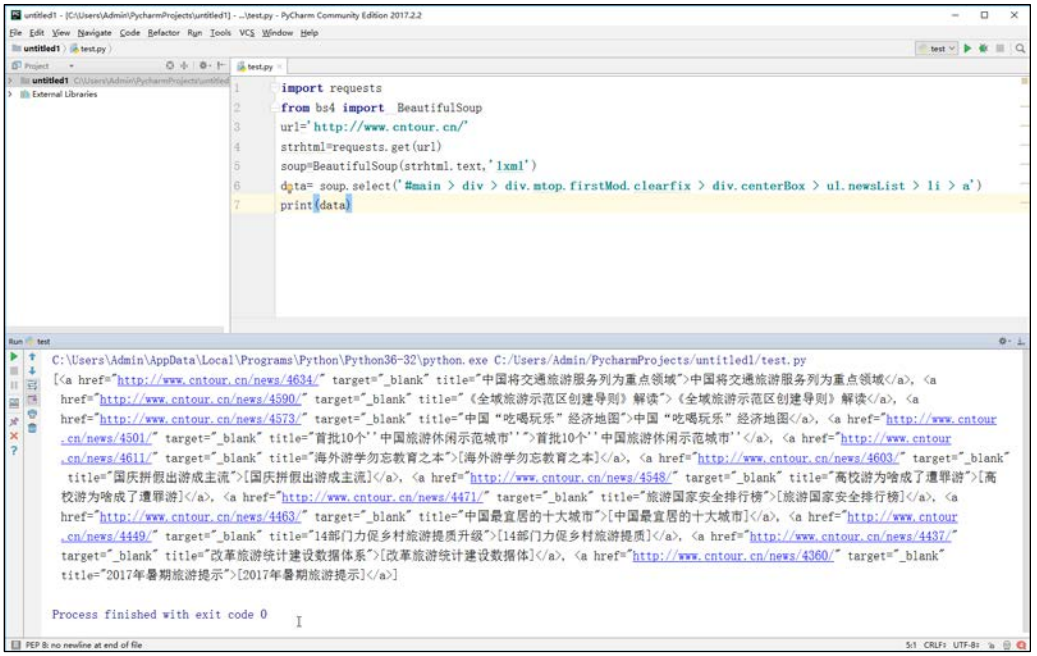

图 2-19

首先，HTML 文档将被转换成 Unicode 编码格式，然后 Beautiful Soup 选择最合适的解析器来解析这段文档，此处指定 lxml 解析器进行解析。解析后便将复杂的 HTML 文档转换成树形结构，并且每个节点都是 Python 对象。这里将解析后的文档存储到新建的变量 soup 中，代码如下。

```
soup=BeautifulSoup(strhtml.text,'lxml')
```

接下来用 select（选择器）定位数据，定位数据时需要使用浏览器的开发者模式，将鼠标光标停留在对应的数据位置并右击，然后在快捷菜单中选择“检查”命令，如图 2-20 所示。

图 2-20

随后在浏览器右侧会弹出开发者界面，右侧高亮的代码（参见图 2-21（b））对应着左侧高亮的数据文本（参见图 2-21（a））。右击右侧高亮数据，在弹出的快捷菜单中选择“Copy”→“Copy Selector”命令，便可以自动复制路径。

（a）

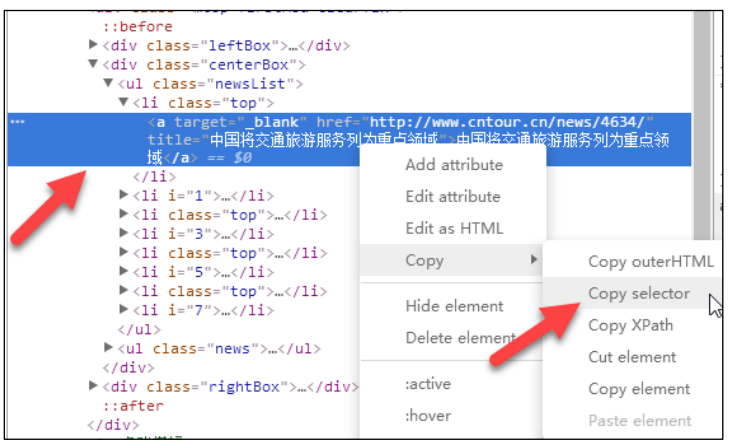

（b）

图 2-21

将路径粘贴在文档中，代码如下。

```
    #main > div > div.mtop.firstMod.clearfix > div.centerBox > ul.newsList > li:nth-child(1) > a
```

由于这条路径是选中的第一条的路径，而我们需要获取所有的头条新闻，因此将 li:nth-child(1) 中冒号（包含冒号）后面的部分删掉，代码如下。

```
    #main > div > div.mtop.firstMod.clearfix > div.centerBox > ul.newsList > li > a
```

使用 soup.select 引用这个路径，代码如下。

```
    data= soup.select('#main > div > div.mtop.firstMod.clearfix > div.centerBox > ul.newsList > li > a')
```

2.5 清洗和组织数据

至此，获得了一段目标的 HTML 代码，但还没有把数据提取出来，接下来在 PyCharm 中输入以下代码。

```
for item in data:                    #soup 匹配到的有多个数据，用 for 循环取出
    result={
       'title':item.get_text(),
       'link':item.get('href')
    }
    print(result)
```

代码运行结果如图 2-22 所示。

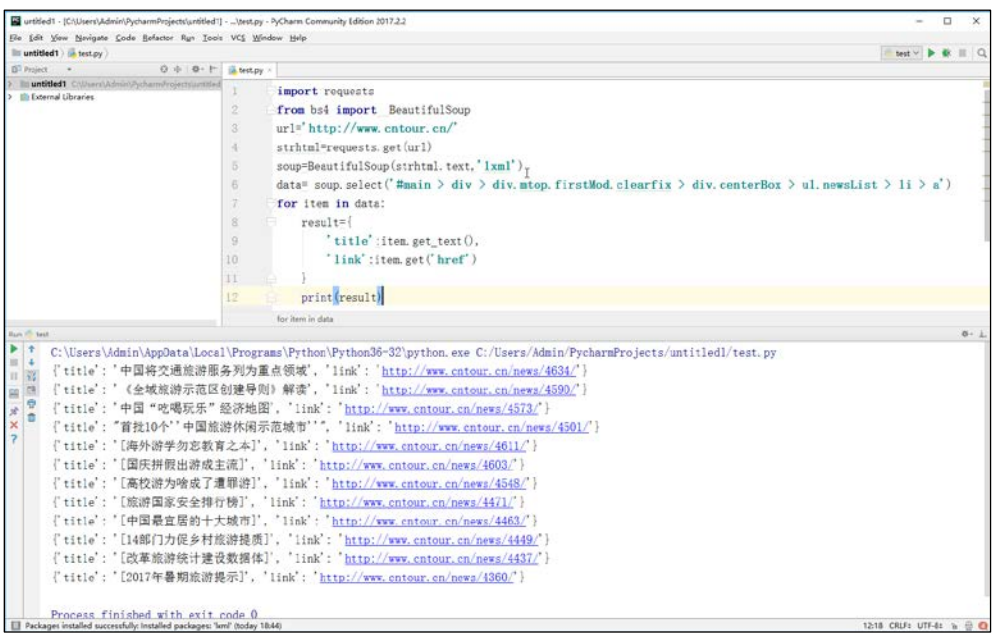

图 2-22

首先明确要提取的数据是标题和链接，标题在<a>标签中，提取标签的正文用 get_text()方法。链接在<a>标签的 href 属性中，提取标签中的 href 属性用 get()方法，在括号中指定要提取的属性数据，即 get('href')。

从图 2-23 中可以发现，每一篇文章的链接中都有一个数字 ID。下面用正则表达式提取这个 ID。

图 2-23

需要使用的正则符号如下。

\d　匹配数字

+　匹配前一个字符 1 次或多次

在 Python 中调用正则表达式时使用 re 库，这个库不用安装，可以直接调用。在 PyCharm 中输入以下代码。

```
import re

for item in data:
    result={
        'title':item.get_text(),
        'link':item.get('href'),
        'ID':re.findall('\d+',item.get('href'))
    }
    print(result)
```

运行结果如图 2-24 所示。

这里使用 re 库的 findall 方法，第一个参数表示正则表达式，第二个参数表示要提取的文本。

2.6 爬虫攻防战

爬虫是模拟人的浏览访问行为，进行数据的批量抓取。当抓取的数据量逐渐增大时，会给被访问的服务器造成很大的压力，甚至有可能崩溃。换句话就是说，服务器是不喜欢有人抓取自己的数据的。那么，网站方面就会针对这些爬虫者，采取一些反爬策略。

服务器第一种识别爬虫的方式就是通过检查连接的 useragent 来识别到底是浏览器访问，还是代码访问的。如果是代码访问的话，访问量增大时，服务器会直接封掉来访 IP。

那么应对这种初级的反爬机制，我们应该采取何种举措?

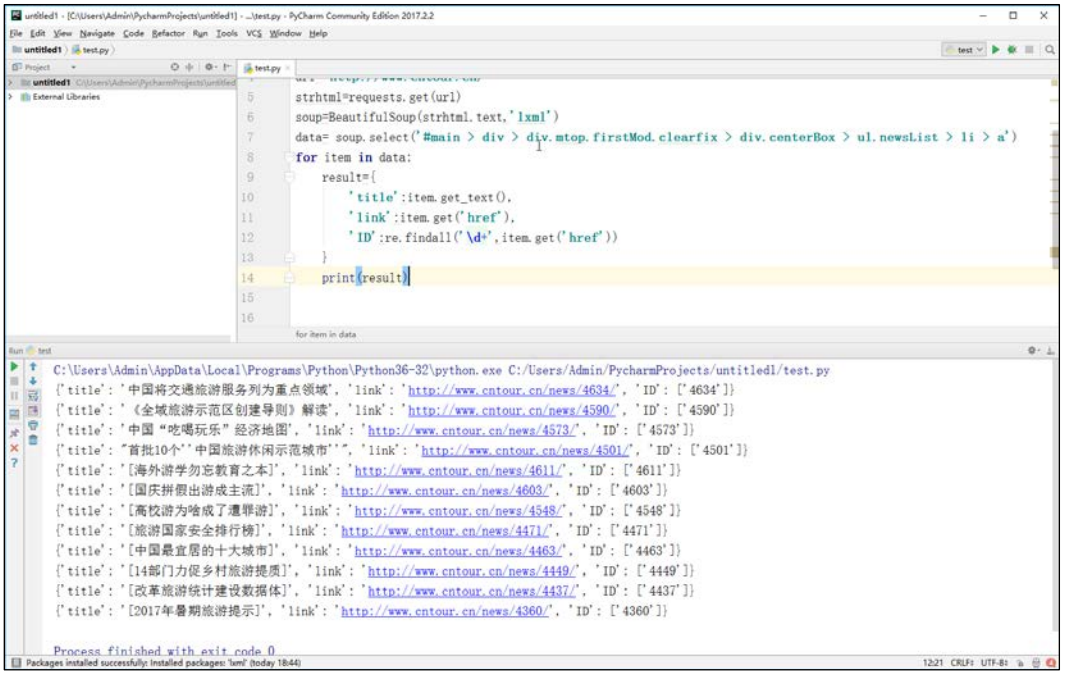

图 2-24

还是以 2.3 小节的爬虫为例。在进行访问时，我们在开发者环境下不仅可以找到 URL、Form Data，还可以在 Request headers 中构造浏览器的请求头，封装自己。服务器识别浏览器访问的方法就是判断 keywor 是否为 Request headers 下的 User-Agent，如图 2-25 所示。因此，我们只需要构造这个请求头的参数。创建请求头部信息即可，代码如下。

```
    headers = {'User-Agent': 'Mozilla/5.0 (Windows NT 6.1; WOW64)
AppleWebKit/537.36 (KHTML, like Gecko) Chrome/43.0.2357.124 Safari/537.36'}
    response = requests.get(url, headers=headers)
```

写到这里，很多读者会认为修改 User – Agent 很太简单。确实很简单，但是正常人 1 秒看一个图，而个爬虫 1 秒可以抓取好多张图，比如 1 秒抓取上百张图，那么服务器的压力必然会增大。也就是说，如果在一个 IP 下批量访问下载图片，这个行为不符合正常人类的行为，肯定要被封 IP。其原理也很简单，就是统计每个 IP 的访问频率，该频率超过阈值，就会返回一个验证码，如果真的是用户访问的话，用户就会填写，然后继续访问，如果是代码访问的话，就会被封 IP。

这个问题的解决方案有两个，第一个就是常用的增设延时，每 3 秒钟抓取一次，代码如下。

```
    import time
    time.sleep(3)
```

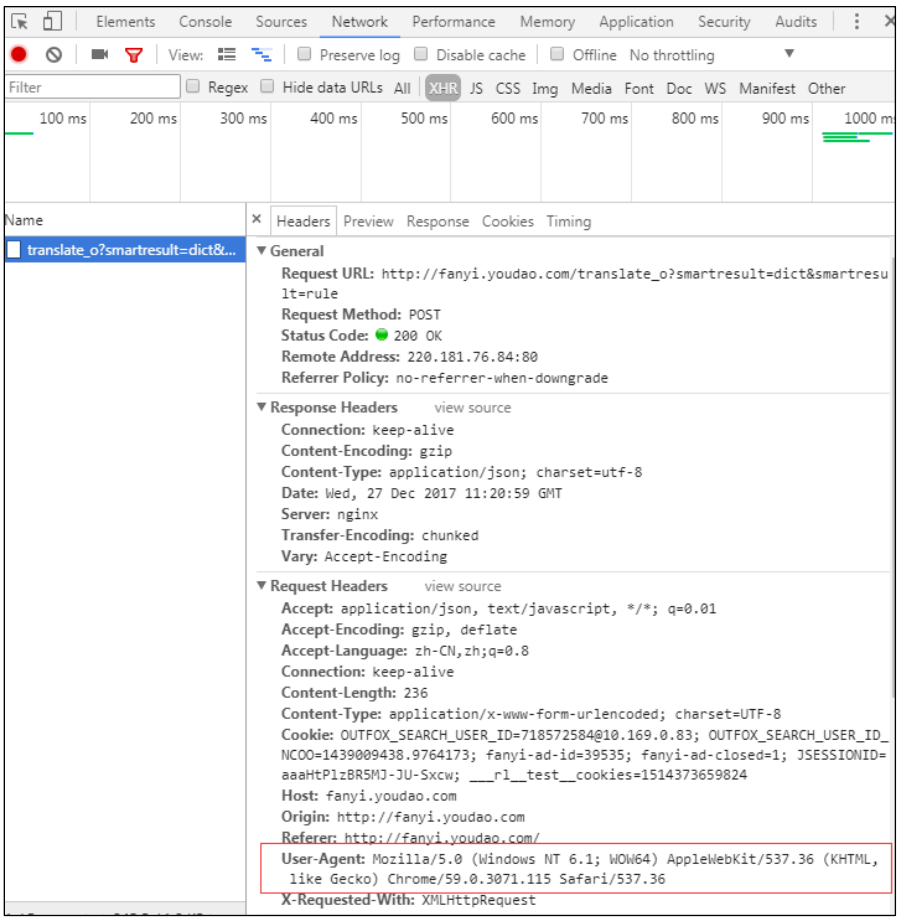

图 2-25

但是，我们写爬虫的目的是为了高效批量抓取数据，这里设置 3 秒钟抓取一次，效率未免太低。其实，还有一个更重要的解决办法，那就是从本质上解决问题。

不管如何访问，服务器的目的就是查出哪些为代码访问，然后封锁 IP。解决办法：为避免被封 IP，在数据采集时经常会使用代理。当然，requests 也有相应的 proxies 属性。

首先，构建自己的代理 IP 池，将其以字典的形式赋值给 proxies，然后传输给 requests，代码如下。

```
proxies = {
  "http": "http://10.10.1.10:3128",
  "https": "http://10.10.1.10:1080",
}
response = requests.get(url, proxies=proxies)
```

第 3 章

用 API 爬取天气预报数据

3.1 注册免费 API 和阅读技术文档

本章示例接口为和风天气的天气预报，该网站为个人开发者提供免费的预报数据（有访问次数限制）。

注册地址：http://console.heweather.com

读者可自行访问官网注册，注册后在控制台看到个人认证的 key（密钥），这个 key 是访问 API 的钥匙，如图 3-1 所示。

图 3-1

获取 key 之后，下一步是阅读 API 说明（开发者）文档。

文档地址：https://www.heweather.com/documents/api/v5/url

免费用户只能访问一个服务器节点，其对应的接口地址如图 3-2 所示。

接口地址

	服务器节点	接口地址
付费用户	中国、北美、欧洲、东南亚	https://api.heweather.com/v5/
免费用户	中国	https://free-api.heweather.com/v5/

图 3-2

接下来了解调用接口的方法。一般首次阅读说明文档时最好按次序阅读，从图 3-3 中可以看出这里共有 3 个参数。

（1）city：代表城市，可以用汉字、拼音、城市代码、经纬度。

（2）key：代表用户的密钥。

（3）lang：代表语言，这个参数默认是中文，而且是可选参数。

了解参数后，这里确定要使用的参数是 1 和 2。根据提示，组合接口地址，如下所示。

https://free-api.heweather.com/v5/weather?city=beijing&key= 7d0daf2a85f64736a42261161cd3060b

API说明文档

v5接口说明

接口地址

全部天气-weather

3-10天预报-forecast

实况天气-now

未来每小时预报-hourly

空气质量实况和预报-AQI

生活指数-suggestion

全国景点天气-scenic

灾害预警-alarm

历史天气-historical

全部天气-weather

包括7-10天预报、实况天气、每小时天气、灾害预警、生活指数、空气质量，一次获取足量数据

此接口含有付费数据，免费用户调用时，一些数据不会返回

参数

参数	描述	选择	示例值
city	城市名称，city可通过城市中英文名称、ID、IP和经纬度进行查询，经纬度查询格式为：经度,纬度	必选	city=北京，city=beijing，city=CN101010100，city= 60.194.130.1，city=120.343,36.088
key	用户认证key	必选	your key
lang	多语言，可以不使用该参数，默认为中文	可选	详见多语言参数值

请求URL示例

付费用户：https://api.heweather.com/v5/weather?city=yourcity&key=yourkey

免费用户：https://free-api.heweather.com/v5/weather?city=yourcity&key=yourkey

图 3-3

只要编写代码访问接口地址，就可以返回数据。服务器返回的数据是 JSON 格式的数据，也就是 Python 中的字典。

通过阅读城市代码内容，可以知道 API 提供了 3181 个城市的天气预报，如图 3-4 所示。

图 3-4

城市代码可以拷贝到本地文件，也可以通过 requests.get()直接从网上获取，如图 3-5 所示。

城市/地区编码	英文	中文	国家代码		国家英文		国家中文		省英文	省中文	所属上级市英文	所属上级市中文	纬度	经度
CN101010100	beijing	北京	CN	China	中国	beijing	北京	beijing	北京	39.904989	116.405285			
CN101010200	haidian	海淀	CN	China	中国	beijing	北京	beijing	北京	39.956074	116.310316			
CN101010300	chaoyang		朝阳	CN	China	中国	beijing	北京	beijing	北京	39.921489	116.486409		
CN101010400	shunyi	顺义	CN	China	中国	beijing	北京	beijing	北京	40.128936	116.653525			
CN101010500	huairou	怀柔	CN	China	中国	beijing	北京	beijing	北京	40.324272	116.637122			
CN101010600	tongzhou		通州	CN	China	中国	beijing	北京	beijing	北京	39.902486	116.658603		
CN101010700	changping		昌平	CN	China	中国	beijing	北京	beijing	北京	40.218085	116.235906		
CN101010800	yanqing	延庆	CN	China	中国	beijing	北京	beijing	北京	40.465325	115.985006			
CN101010900	fengtai	丰台	CN	China	中国	beijing	北京	beijing	北京	39.863642	116.286968			
CN101011000	shijingshan	石景山	CN	China	中国	beijing	北京	beijing	北京	39.914601	116.195445			
CN101011100	daxing	大兴	CN	China	中国	beijing	北京	beijing	北京	39.728908	116.338033			
CN101011200	fangshan		房山	CN	China	中国	beijing	北京	beijing	北京	39.735535	116.139157		
CN101011300	miyun	密云	CN	China	中国	beijing	北京	beijing	北京	40.377362	116.843352			
CN101011400	mentougou		门头沟	CN	China	中国	beijing	北京	beijing	北京	39.937183	116.105381		
CN101011500	pinggu	平谷	CN	China	中国	beijing	北京	beijing	北京	40.144783	117.112335			
CN101011600	dongcheng		东城	CN	China	中国	beijing	北京	dongcheng	东城	39.917544	116.418757		
CN101011700	xicheng	西城	CN	China	中国	beijing	北京	xicheng	西城	39.915309	116.366794			
CN101020100	shanghai		上海	CN	China	中国	shanghai		上海	shanghai	上海	31.231706	121.472644	
CN101020200	minhang	闵行	CN	China	中国	shanghai		上海	shanghai		上海	31.111658	121.375972	
CN101020300	baoshan	宝山	CN	China	中国	shanghai		上海	shanghai		上海	31.398896	121.489934	
CN101020400	huangpu	黄浦	CN	China	中国	shanghai		上海	huangpu	黄浦	31.222771	121.490317		
CN101020500	jiading	嘉定	CN	China	中国	shanghai		上海	shanghai		上海	31.383524	121.250333	
CN101020600	pudongxinqu		浦东新区		CN	China	中国	shanghai		上海	shanghai		上海	31.245944	121.567706
CN101020700	jinshan	金山	CN	China	中国	shanghai		上海	shanghai		上海	30.724697	121.330736	
CN101020800	qingpu	青浦	CN	China	中国	shanghai		上海	shanghai		上海	31.151209	121.113021	
CN101020900	songjiang		松江	CN	China	中国	shanghai		上海	shanghai		上海	31.03047	121.223543
CN101021000	fengxian		奉贤	CN	China	中国	shanghai		上海	shanghai		上海	30.912345	121.458472
CN101021100	chongming		崇明	CN	China	中国	shanghai		上海	shanghai		上海	31.626946	121.397516
CN101021200	xuhui	徐汇	CN	China	中国	shanghai		上海	shanghai		上海	31.179973	121.43752	
CN101021300	changning		长宁	CN	China	中国	shanghai		上海	changning	长宁	31.218123	121.4222	
CN101021400	jingan	静安	CN	China	中国	shanghai		上海	jingan	静安	31.229003	121.448224		
CN101021500	putuo	普陀	CN	China	中国	shanghai		上海	putuo	普陀	31.241701	121.392499		
CN101021600	hongkou	虹口	CN	China	中国	shanghai		上海	hongkou	虹口	31.26097	121.491832		
CN101021700	yangpu	杨浦	CN	China	中国	shanghai		上海	yangpu	杨浦	31.270755	121.522797		

图 3-5

3.2 获取 API 数据

通过 3.1 节，我们知道 API 提供了全国 3181 个城市的天气预报，可以通过互联网在线爬取或读取城市列表，然后通过循环语句一次性获取 3181 个城市的天气预报。通过阅读文档读取 API 提供的城市，其城市数量是会变动的，因此最好的方式是直接从网上读取，这样就可以省去人工更新城市列表的工作了。

从网上读取数据的第一步是获取城市列表，然后根据城市列表循环，代码如下。

```
import requests
url='https://cdn.heweather.com/china-city-list.txt'
strhtml=requests.get(url)
data=strhtml.text
data1=data.split("\n")
for i in range(3):
    data1.remove(data1[0])
for item in data1:
    print(item[0:11])
```

运行上面这段代码可以提取所有的城市代码，如图 3-6 所示。

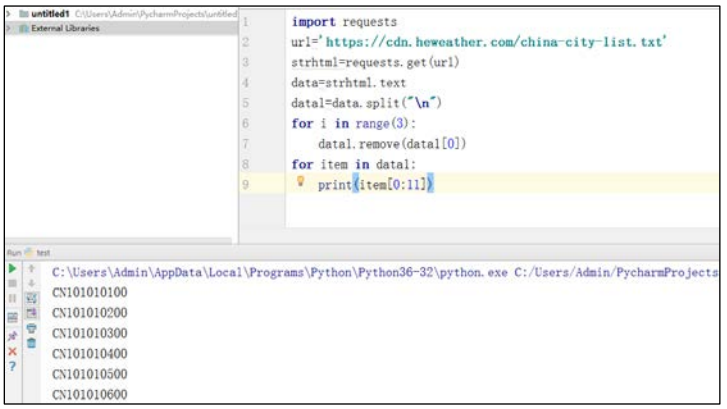

图 3-6

接下来通过 requests.get()获取数据，代码如下。

```
strhtml=requests.get(url)
print(data)
```

观察打印出来的数据，可以发现并不需要前三行，如图 3-7 所示。

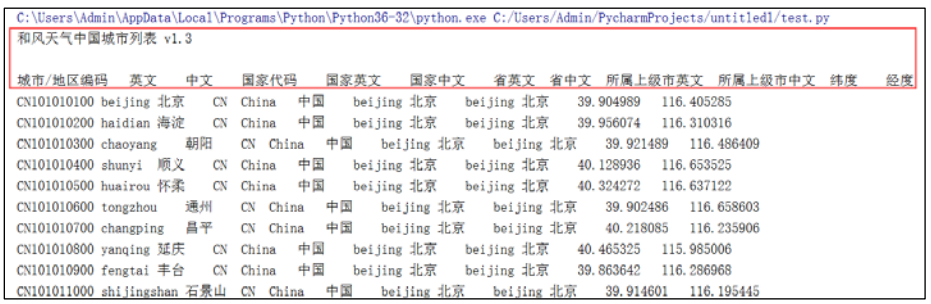
C:\Users\Admin\AppData\Local\Programs\Python\Python36-32\python.exe C:/Users/Admin/PycharmProjects/untitled1/test.py
和风天气中国城市列表 v1.3
城市/地区编码 英文 中文 国家代码 国家英文 国家中文 省英文 省中文 所属上级市英文 所属上级市中文 纬度 经度
CN101010100 beijing 北京 CN China 中国 beijing 北京 beijing 北京 39.904989 116.405285
CN101010200 haidian 海淀 CN China 中国 beijing 北京 beijing 北京 39.956074 116.310316
CN101010300 chaoyang 朝阳 CN China 中国 beijing 北京 beijing 北京 39.921489 116.486409
CN101010400 shunyi 顺义 CN China 中国 beijing 北京 beijing 北京 40.128936 116.653525
CN101010500 huairou 怀柔 CN China 中国 beijing 北京 beijing 北京 40.324272 116.637122
CN101010600 tongzhou 通州 CN China 中国 beijing 北京 beijing 北京 39.902486 116.658603
CN101010700 changping 昌平 CN China 中国 beijing 北京 beijing 北京 40.218085 116.235906
CN101010800 yanqing 延庆 CN China 中国 beijing 北京 beijing 北京 40.465325 115.985006
CN101010900 fengtai 丰台 CN China 中国 beijing 北京 beijing 北京 39.863642 116.286968
CN101011000 shijingshan 石景山 CN China 中国 beijing 北京 beijing 北京 39.914601 116.195445

图 3-7

接下来用 split 方法将文本转变成列表，然后通过一个循环将前三行内容删除。

然后将一大串文本分割出来，这里可以用换行符将每一行文本分开。在 Python 中，\n 表示换行符。

```
    data1=data.split("\n")
```

删除数据使用的是 remove 方法，并且每次都删除第一行（序号为 0）数据。因为每次删除第一行数据，所以第二行数据都会变成下次执行的第一行数据，代码如下。

```
    for i in range(3):
        data1.remove(data1[0])
```

通过前面的接口信息，可以知道只要获取城市/地区编码就可以了。这里从便捷的角度出发，提取每一行的前 12 个字符，然后通过一个列表元素循环，将城市编码打印出来。

```
    for item in data1:
        print(item[0:11])
```

完成了城市编码的提取后，下一步就是调用接口获取数据，代码如下。

```
    import requests
    import time
    url='https://cdn.heweather.com/china-city-list.txt'
    strhtml=requests.get(url)
    data=strhtml.text
    data1=data.split("\n")
    for i in range(3):
        data1.remove(data1[0])
    for item in data1:
        url = 'https://free-api.heweather.com/v5/forecast?city=' + item[0:11]
+ '&key=7d0daf2a85f64736a42261161cd3060b'
        strhtml = requests.get(url)
        time.sleep(1)
        print(strhtml.text)
```

数据是以 JSON 的格式返回的，每一个城市/地区都是一个 JSON，如图 3-8 所示。

这段代码调用了 time 库，这是为了使用 sleep（睡眠）函数，也就是延时函数。因为 API 提供了 3181 个城市/地区，这个循环就要执行 3181 次。为了避免访问服务器过于频繁，保证爬虫的稳定性，这里让程序每次访问后等待 1 秒钟。在写爬虫的时候不管需要访问的次数是多还是少，最好养成写延时的习惯，延时函数代码如下。

```
    time.sleep(1)
```

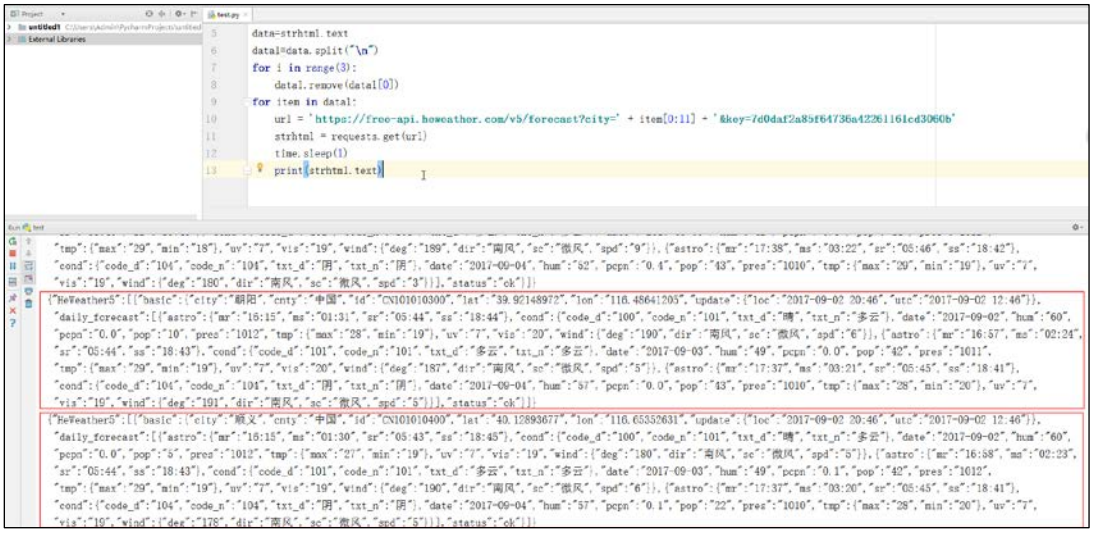

图 3-8

如果要将返回的 JSON 数据解析出来，可以使用 for 循环语句。

```
    import requests
    import time
    url='https://cdn.heweather.com/china-city-list.txt'
    strhtml=requests.get(url)
    data=strhtml.text
    data1=data.split("\n")
    for i in range(3):
        data1.remove(data1[0])
    for item in data1:
        url = 'https://free-api.heweather.com/v5/forecast?city=' + item[0:11]
+ '&key=7d0daf2a85f64736a42261161cd3060b'
        strhtml = requests.get(url)
        time.sleep(1)
        dic =strhtml.json()
    for item in dic["HeWeather5"][0]["daily_forecast"]:
        print(item["tmp"]["max"])
```

代码执行结果如图 3-9 所示。

接下来使用 JSON 在线结构化的工具观察数据结构，网址如下。

```
    http://www.json.org.cn/tools/JSONEditorOnline/index.htm
```

将其中一个城市的返回数据复制、粘贴到左侧的文本框中，然后单击中间的向右箭头，就会得到如图 3-10 所示的结果。通过观察路径,3 天的预报数据是在[**HeWeather5**] [0][**daily_forecast**]

下面，由[0]、[1]和[2]这 3 个数据节点分别存放 3 天的数据，而每天的最高温度是在[**HeWeather5**][0][**daily_forecast**][n][**tmp**][**max**]路径下，其中[n]表示分节点[0]、[1]、[2]。

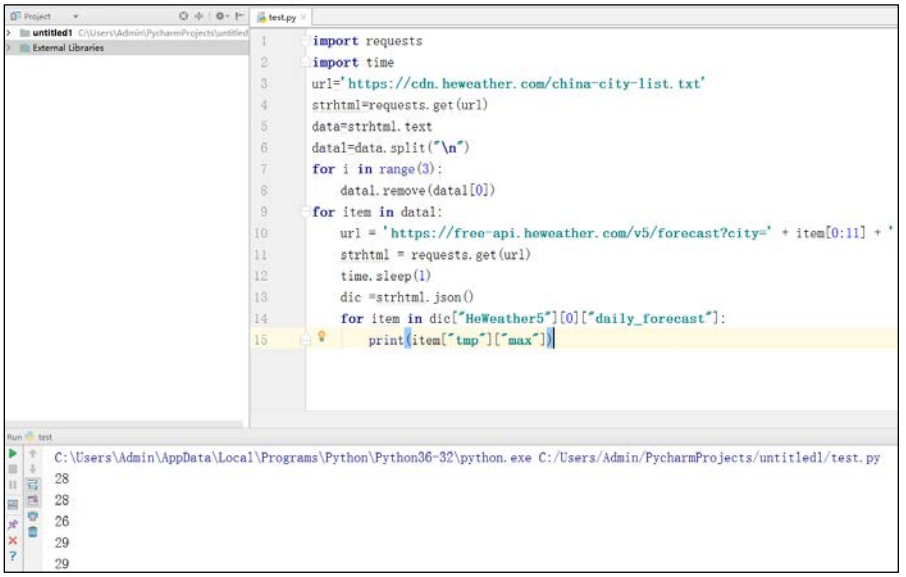

图 3-9

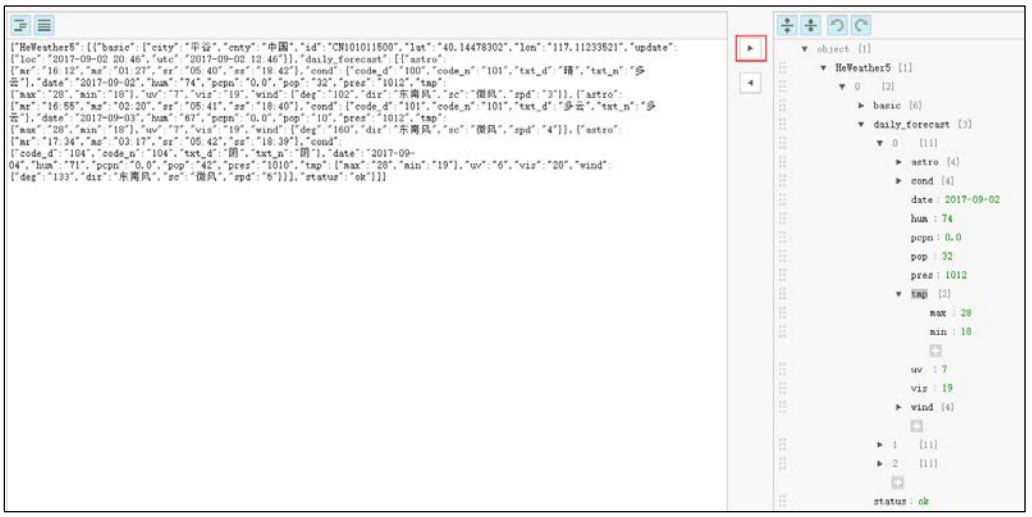

图 3-10

如果 JSON 工具报错，则需要检查复制的内容是否存在多了空格或者少了符号之类的问题，这些都是新手常犯的错误。

requests 库返回的数据可以编码成 JSON 格式的数据，只有 JSON 对象才可以适用上面分析的路径，表现方式如下。

```
strhtml.json()
```

3.3 存储数据到 MongoDB

MongoDB 是一个基于分布式文件存储的数据库，由 C++语言编写，旨在为 Web 应用提供可扩展的高性能数据存储解决方案。

MongoDB 是一个介于关系数据库和非关系数据库之间的产品，它在非关系数据库中功能最丰富、最像关系数据库。

3.3.1 下载并安装 MongoDB

1．下载 MongoDB

官网下载：https://www.mongodb.com/download-center#community

百度网盘：http://pan.baidu.com/s/1b7Ll1s

2．配置本地 MongoDB

每次启动时都需要在 CMD 中配置，找到安装目录下的 bin 文件夹路径，如图 3-11 所示。

图 3-11

由 CMD 进入以下路径，如下所示。

```
>cd C:\Program Files\MongoDB\Server\3.2\bin
```

配置数据库路径，配置前要先在 C 盘中新建文件夹，代码如下。

```
mongod --dbpath C:\data\db
```

代码运行结果如下所示。

```
2017-12-21T16:04:34.478+0800 I CONTROL  [initandlisten] MongoDB starting :
pid=4156 port=27017 dbpath=c:\data\db 64-bit host=DESKTOP-F5UIIPN
2017-12-21T16:04:34.479+0800  I  CONTROL   [initandlisten]  targetMinOS:
Windows 7/Windows Server 2008 R2
……（省略中间内容）
2017-12-21T16:04:35.175+0800  I  FTDC       [initandlisten]  Initializing
full-time diagnostic data capture with directory 'c:/data/db/diagnostic.data'
2017-12-21T16:04:35.179+0800 I NETWORK  [thread1] waiting for connections
```

```
on port 27017
```

再打开一个 CMD，进入 MongoDB 确认数据库已经启动，进入 bin 路径，如下所示。

```
>cd C:\Program Files\MongoDB\Server\3.2\bin
```

键入 mongo 连接数据库，显示“>”就代表 MongoDB 已经正常启动，如下所示。

```
C:\Program Files\MongoDB\Server\3.4\bin>mongo
MongoDB shell version v3.2.1
connecting to: mongodb://127.0.0.1:27017
>
```

3.3.2 在 PyCharm 中安装 Mongo Plugin

在 PyCharm 中的菜单，依次选择“File”命令→选择“settings”命令→选择“plugins”命令→选择“browse repositories”命令→输入“mongo”，然后选择 Mongo Plugin，如图 3-12 和图 3-13 所示。

安装好后重启 PyCharm，就可以在右侧看到 Mongo Explorer。

如果没有这个窗口，可以将鼠标光标停留在左下角的图标上，然后在自动弹出的菜单中选择 Mongo Explorer 命令，如图 3-14 所示。

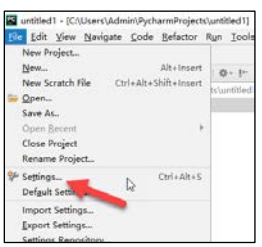

图 3-12

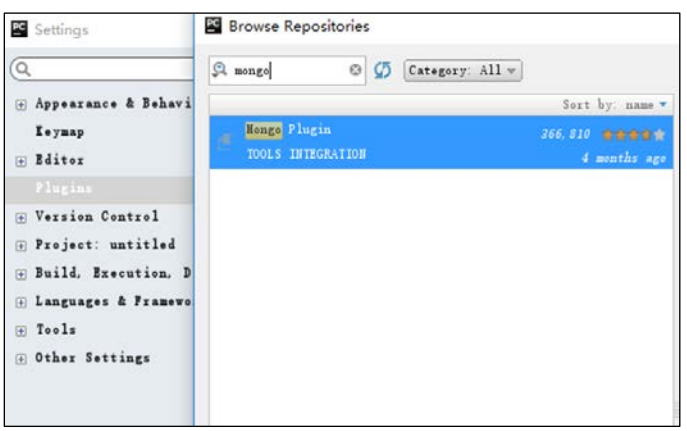

图 3-13

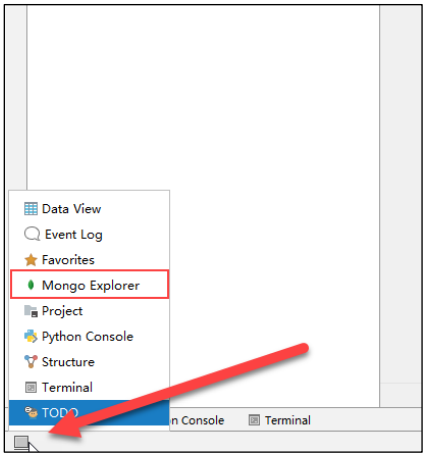

图 3-14

接下来在 Mongo Explorer 窗口中单击设置按钮，创建连接（在 PyCharm File 菜单的 Setting 中也可以设置），如图 3-15 所示。

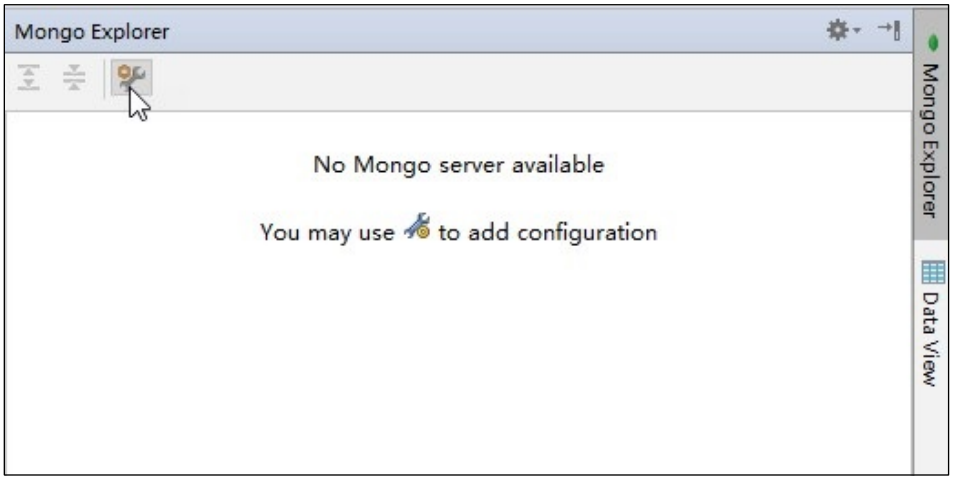

图 3-15

在 Mongo Servers 设置窗口中单击左侧加号按钮（addServer），如图 3-16 所示。

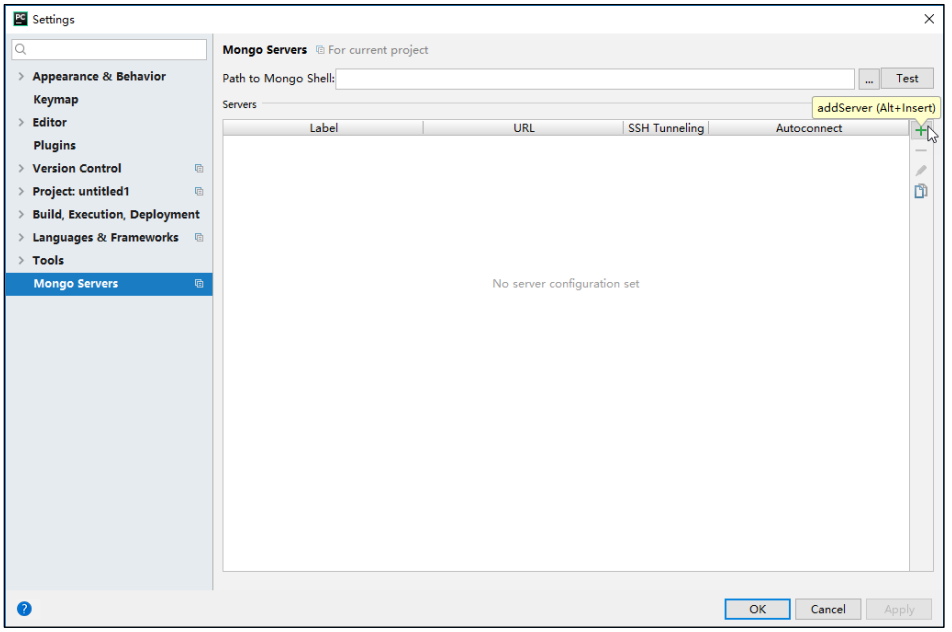

图 3-16

输入连接名，然后单击“Test Connection”（测试连接）按钮，提示信息为“Connection test successful”时表示连接正常，然后单击右下角的“OK”按钮，保存设置即可，如图 3-17 所示。

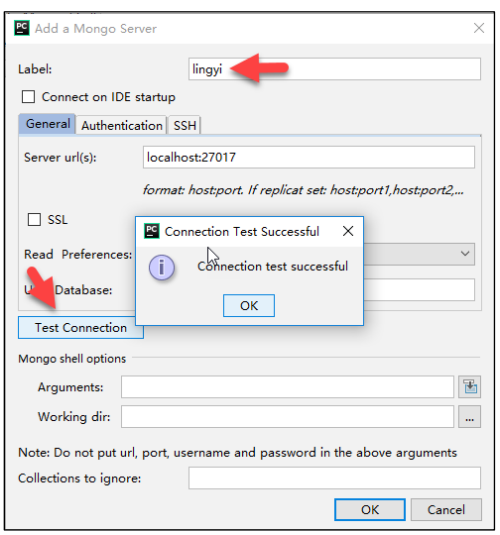

图 3-17

3.3.3　将数据存入 MongoDB

下面尝试将获取的数据存入 MongoDB 中，首先输入以下这段代码。

```
    import requests
    import time
    #加载 pymongo 库
    import pymongo
    #建立连接
    client=pymongo.MongoClient('localhost',27017)
    #在 MongoDB 中新建名为 weather 的数据库
    book_weather=client['weather']
    #在 weather 库中新建名为 sheet_weather_3 的表
    sheet_weather=book_weather['sheet_weather_3']
    url='https://cdn.heweather.com/china-city-list.txt'
    strhtml=requests.get(url)
    data=strhtml.text
    data1=data.split("\n")
    for i in range(3):
        data1.remove(data1[0])
    for item in data1:
        url = 'https://free-api.heweather.com/v5/forecast?city=' + item[0:11]
+ '&key=7d0daf2a85f64736a42261161cd3060b'
        strhtml = requests.get(url)
        time.sleep(1)
        dic =strhtml.json()
        #向表写入一条数据
        sheet_weather.insert_one(dic)
```

运行后双击连接，可以看到名为 weather 的数据库，如图 3-18 所示。

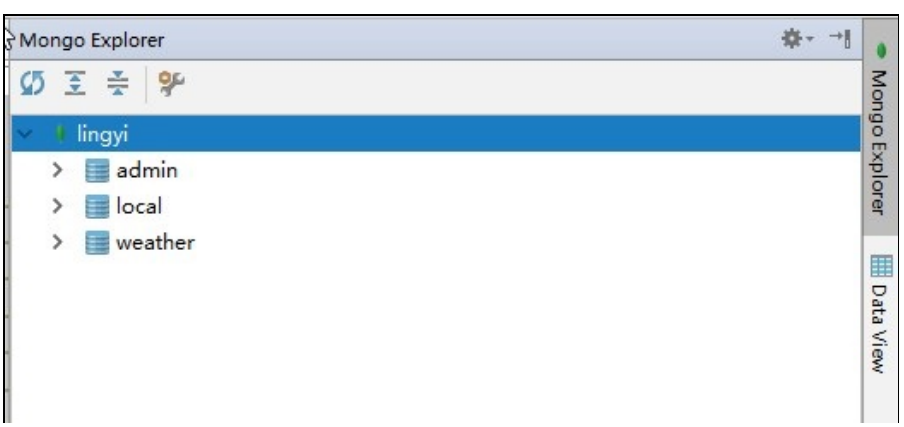

图 3-18

展开 weather 数据库，双击 sheet_weather_3 这张表（参见图 3-19（b）），会弹出预览窗口（参见图 3-19（a）），可以从该窗口观察获取到的天气数据，数据以 JSON 格式存在数据库中。

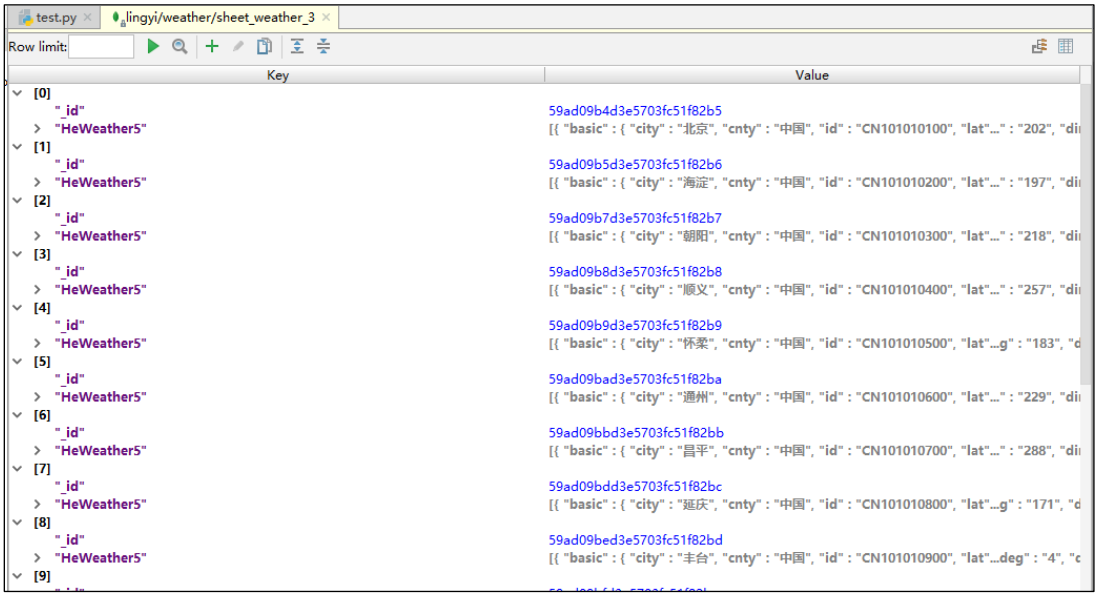

（a）

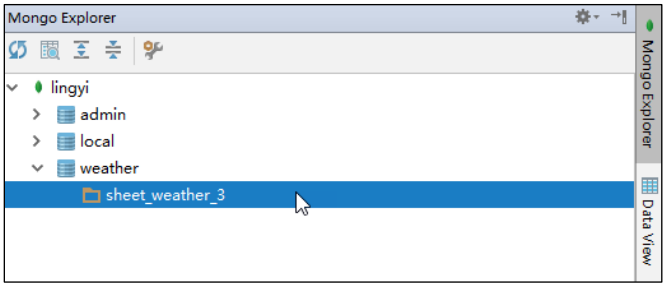

（b）

图 3-19

可以直接在预览窗口中展开 JSON 的树状结构，如图 3-20 所示。

图 3-20

需要提前安装 PyMongo 库，这是一个提供 Python 和 MongoDB 连接的库，使用方法如下。

1．建立连接

输入以下代码，其中 localhost 是主机名，27017 是端口号（默认情况下是这个参数）。

```
client=pymongo.MongoClient('localhost',27017)
```

2．新建名为'weather'的数据库

输入以下代码。

```
book_weather=client['weather']
```

3．新建名为'sheet_weather_3'的表

输入以下代码。

```
sheet_weather=book_weather['sheet_weather_3']
```

4．写入数据

输入以下代码。

```
sheet_weather.insert_one(dic)
```

3.4 MongoDB 数据库查询

基于 3.3 节的结果，查询北京的天气数据，代码如下。

```
import pymongo
client=pymongo.MongoClient('localhost',27017)
book_weather=client['weather']
sheet_weather=book_weather['sheet_weather_3']
#查找键 HeWeather5.basic.city 值为北京的数据
for item in sheet_weather.find({'HeWeather5.basic.city':'北京'}):
    print(item)
```

代码运行结果如图 3-21 所示。

图 3-21

查询的语法是 sheet_weather.find()，其中 sheet_weather 代表 weather，数据库中的表格 sheet_weather_3。

接下来查询天气最低气温大于 5 摄氏度的城市名，代码如下。

```
import pymongo
client=pymongo.MongoClient('localhost',27017)
book_weather=client['weather']
sheet_weather=book_weather['sheet_weather_3']
for item in sheet_weather.find():
    #因为数据需要 3 天的天气预报，因此循环 3 次
    for i in range(3):
        tmp=item['HeWeather5'][0]['daily_forecast'][i]['tmp']['min']
```

```
            #使用 update 方法，将表中最低气温数据修改为数值型
            sheet_weather.update_one({'_id':item['_id']},{'$set':{'HeWeather5.
0.daily_forecast.{}.tmp.min'.format(i):int(tmp)}})
    #提取出最低气温低于 5 摄氏度的城市
    for  item  in  sheet_weather.find({'HeWeather5.daily_forecast.tmp.min':
{'$gt':5}}):
        print(item['HeWeather5'][0]['basic']['city'])
```

代码运行结果如图 3-22 所示。

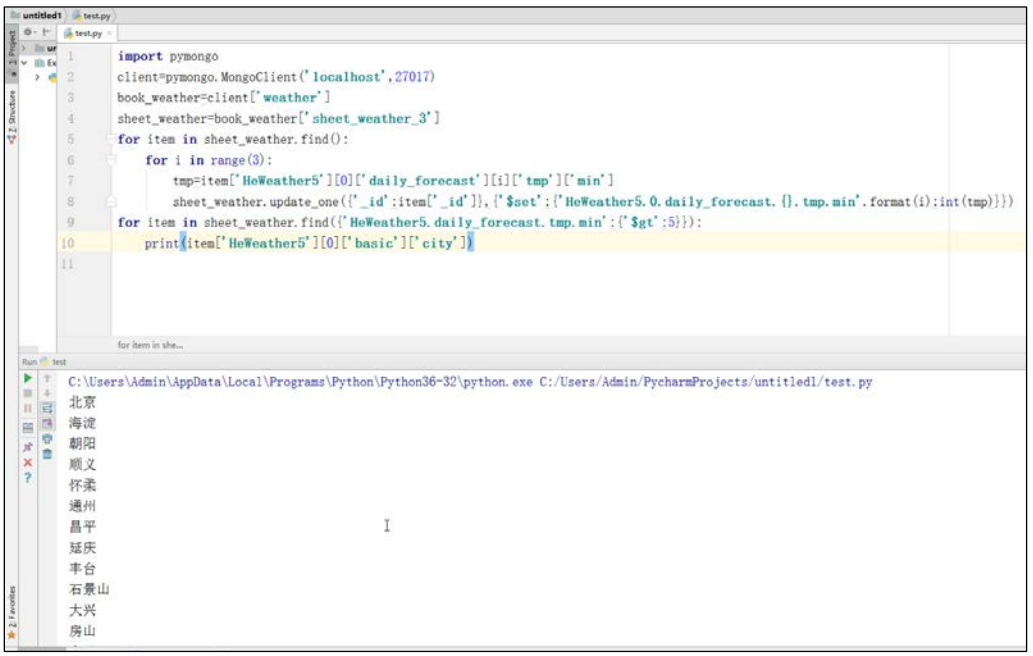

图 3-22

由于这里目标是提取最低温度大于 5 摄氏度的城市名，因此先将最低温度设置成整型数据。更新数据用 sheet_weather.，其中 update_one,update_one 方法用于指定更新一条数据，代码如下。

```
    sheet_weather.update_one({'_id':item['_id']},{'$set':{'HeWeather5.0.dail
y_forecast.{}.tmp.min'.format(i):int(tmp)}})
```

这里第一个参数是{'_id':item['_id']}，表示要更新的查询条件，对应_id 字段。第二个参数表示要更新的信息，$set 是 MongoDB 中的一个修改器，用于指定一个键并更新键值，若键不存在则创建一个键。

除此之外，常用修改器还有$inc、$unset、$push 等。

- 修改器$inc　　可以对文档的某个值为数字型（只能为满足要求的数字）的键进行增减操作。

- 修改器$unset　　用于删除键。
- 修改器$push　　向文档的某个数组类型的键添加一个数组元素，不过滤重复的数据。添加时，若键存在，要求键值类型必须是数组；若键不存在，则创建数组类型的键。

`{'$set':{'HeWeather5.0.daily_forecast.{}.tmp.min'.format(i):int(tmp)}}`是将 `HeWeather5.0.daily_forecast.{}.tmp.min` 路径下的数据设置为 int（整型），路径中间的`{}`的数据由路径后的.format(i)指定，其内容就是 format 中的 i 变量。

下面是一些延伸内容。

可以将 3.2 节中的 URL 部分：

```
    url = 'https://free-api.heweather.com/v5/forecast?city=' + item[0:11] + '&key=7d0daf2a85f64736a42261161cd3060b'
```

写成：

```
    url = 'https://free-api.heweather.com/v5/forecast?city={}&key=7d0daf2a85f64736a42261161cd3060b'.format(item[0:11])
```

数据更新完毕后，再用 find 方法查找数据，其中$gt 表示符号>。

```
    for item in sheet_weather.find({'HeWeather5.daily_forecast.tmp.min':{'$gt':5}}):
        print(item['HeWeather5'][0]['basic']['city'])
```

这里的$lt、$lte、$gt 和$gte，分别表示符号<、≤、>和≥。

第 4 章

大型爬虫案例：抓取某电商网站的商品数据

4.1 观察页面特征和解析数据

本章实例是实现一个大型爬虫，抓取某电商网站中某个频道的所有商品数据。

实现爬虫的第一步是观察页面特征和解析数据。

在第 3 章中，接触了 JSON 格式的数据，JSON 格式的数据比较容易处理，所以在获取数据的时候最好选择 JSON 格式的数据。

通过对比 PC 端和无线端，这里决定数据采集自无线端，原因是无线端返回的数据是 JSON 格式。这里以 touch.qunar.com 的自由行为例，如图 4-1 所示。

图 4-1

在浏览器访问 touch.qunar.com，如图 4-2 所示。

图 4-2

接下来按【F12】键进入开发者模式，单击“自由行”选项进入自由行频道，如图 4-3 所示。

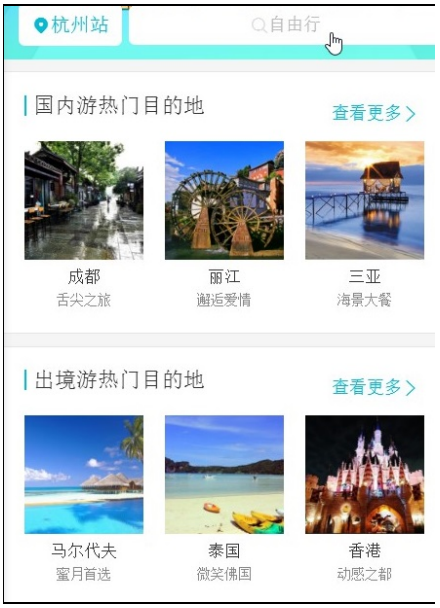

图 4-3

在自由行频道中单击搜索框，如图 4-4 所示。

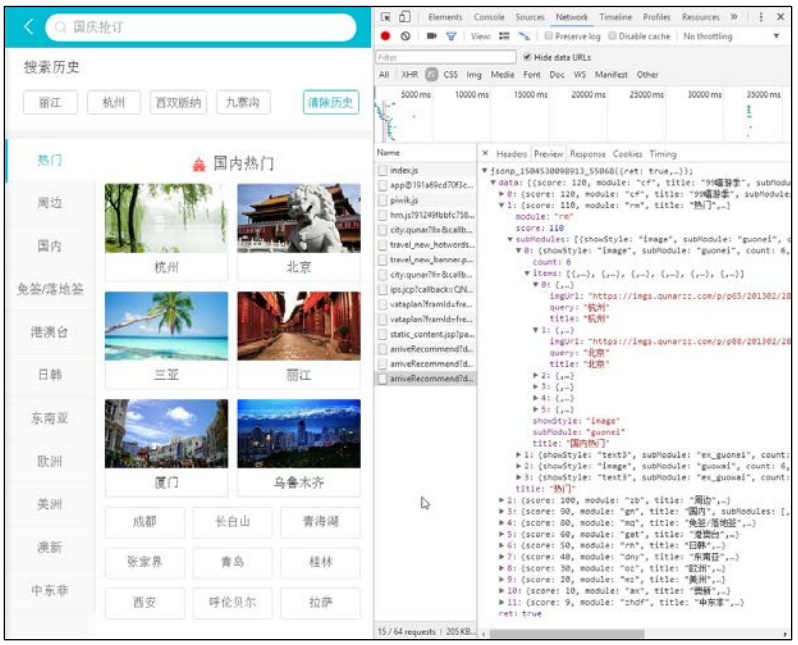

图 4-4

随后进入搜索页面，这个页面有各个地区的热门旅游城市列表（参见图 4-5（a）），以 JS（JScrip）格式读取右侧的数据，在文件的 Preview（预览）页面可以观察到树状的结构（参见图 4-5（b））。

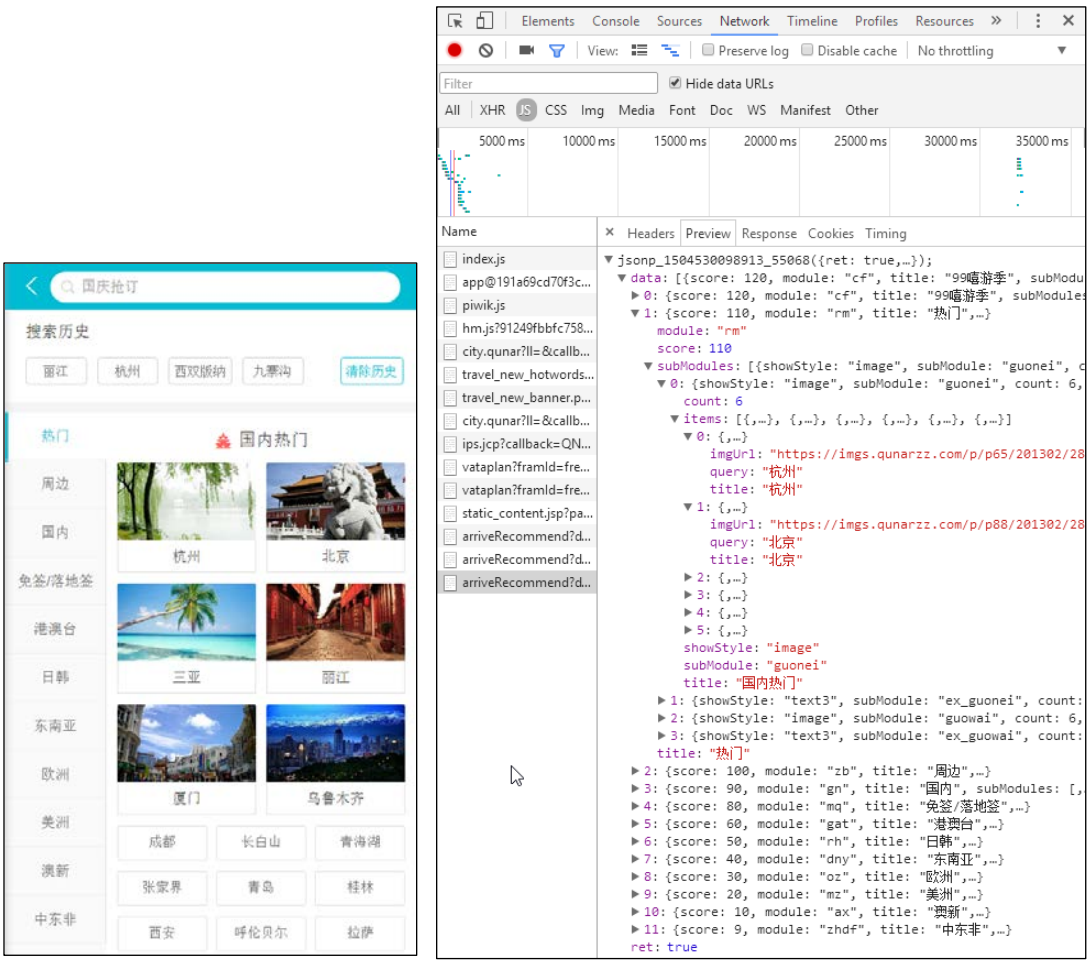

（a）　　（b）

图 4-5

切换到 Headers（请求头）页面，在 General（总体）信息中，有以下两条重要信息。

（1）Request URL（请求链接）：将通过这个链接访问服务器获取数据。

（2）Request Method（请求方法）：决定使用的函数方法和上传参数。常见的请求方法有 GET 方法和 POST 方法，其中 GET 方法权限单一，只有查询数据的权限，只要访问 URL 就可以返回数据；POST 方法需要权限验证和请求内容，服务器通过权限放行，通过请求内容返回客户端请求的数据，POST 方法具有查询和修改数据的权限。

如图 4-6 所示的请求方法即为 GET 方法。

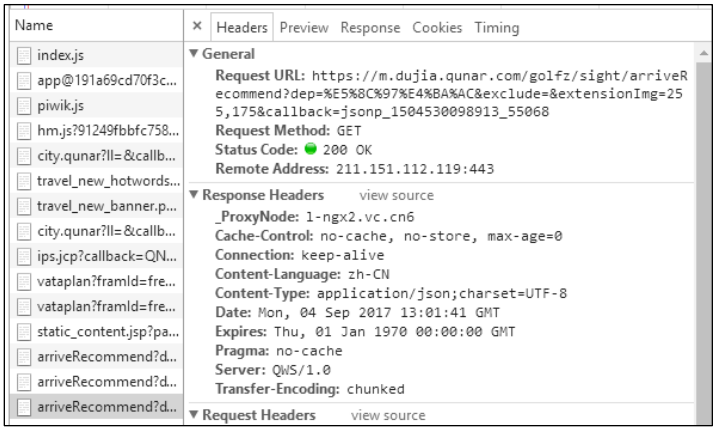

图 4-6

在获取数据的时候，需要将最后一个 callback 参数删掉。

因此，目标 URL 如下。

https://m.dujia.qunar.com/golfz/sight/arriveRecommend?dep=%E5%8C%97%E4%BA%AC&exclude=&extensionImg=255,175

单击推荐列表中的任意一个城市（参见图 4-7（a）），通过观察可以发现数据在 XHR（用 XMLHttpRequest 方法来获取 JavaScript）中（参见图 4-7（b））。

（a）

Elements
Console
Sources
Network
Timeline
Profiles
Resources
Preserve log
Disable cache
No throttling
Filter
Hide data URLs
All
XHR
JS
CSS
Img
Media
Font
Doc
WS
Manifest
Other
20000 ms
40000 ms
60000 ms
80000 ms
100000 ms
Name
Headers
Preview
Response
Cookies
Timing
touch_config.json
list?modules=mobFu...
lst_400phone.json?d...
list?dep=%E6%9D%A...
list?modules=list,bo...
play_comb_list.json?...
{ret: true, data: {activityDetail: [{name: "帆船出海", value: "rou
data: {activityDetail: [{name: "帆船出海", value: "route.destina
activityDetail: [{name: "帆船出海", value: "route.destination.
limit: {agency: 41, groupCount: 168, routeCount: 598}
list: {related: [], numFound: 598,…}
numFound: 598
related: []
results: [{hotelPos: ["鼓浪屿风景区"], duv: 0, discount: "0.8
0: {hotelPos: ["鼓浪屿风景区"], duv: 0, discount: "0.86", ho
1: {hotelPos: ["鼓浪屿风景区"], duv: 0, discount: "0.89", ho
2: {hotelPos: ["鼓浪屿风景区"], duv: 0, discount: "0.83", ho
3: {coreHotelAreas: ["中山路步行街"], hotelPos: ["中山路步行街
4: {hotelPos: null, duv: 0, discount: "0.8", hotDatePrice:
5: {coreHotelAreas: ["中山路步行街"], hotelPos: ["中山路步行街
6: {hotelPos: null, duv: 0, discount: "0.8", hotDatePrice:
7: {hotelPos: ["湖里商业区"], duv: 0, discount: "1.51", hotl
8: {hotelPos: ["梧村"], duv: 0, discount: "0.87", hotDatePr
9: {hotelPos: null, duv: 0, discount: "0.92", hotDatePrice
10: {hotelPos: null, duv: 0, discount: "0.92", hotDatePric
11: {hotelPos: null, duv: 0, discount: "0.92", hotDatePric
12: {hotelPos: ["湖里商业区"], duv: 0, discount: "0.86", ho
13: {hotelPos: null, duv: 0, discount: "0.34", hotDatePric
14: {coreHotelAreas: ["中山路步行街"], hotelPos: ["鼓浪屿风景
15: {hotelPos: null, duv: 0, discount: "0.41", hotDatePric
16: {hotelPos: null, duv: 0, discount: "0.33", hotDatePric
17: {hotelPos: null, duv: 0, discount: "0.39", hotDatePric
18: {hotelPos: ["鼓浪屿风景区", "梧村"], duv: 0, discount:
19: {coreHotelAreas: ["环岛路风景区"], hotelPos: ["环岛路风景
20: {hotelPos: ["梧村", "鼓浪屿风景区"], duv: 0, discount:
21: {hotelPos: null, duv: 0, discount: "0.65", hotDatePric
22: {hotelPos: null, duv: 0, discount: "0.58", hotDatePric
23: {coreHotelAreas: ["环岛路风景区"], hotelPos: ["鼓浪屿风景
24: {coreHotelAreas: ["环岛路风景区"], hotelPos: ["鼓浪屿风景
25: {hotelPos: ["鼓浪屿风景区", "湖里商业区"], duv: 0, discou
26: {hotelPos: null, duv: 0, discount: "0.67", hotDatePric
27: {hotelPos: ["梧村", "湖里商业区", "鼓浪屿风景区"], duv: 0,
28: {hotelPos: ["湖里商业区"], duv: 0, discount: "0.7", hotl
29: {coreHotelAreas: ["中山路步行街", "环岛路风景区"], hotelP
30: {hotelPos: ["梧村", "鼓浪屿风景区"], duv: 0, discount:
31: {coreHotelAreas: ["中山路步行街"], hotelPos: ["鼓浪屿风景
qdata: {abroad: false, aliasWordExtendsMap: {}, around: false
6 / 42 requests | 29.1 KB ...

（b）

图 4-7

切换到 Headers 页面，观察 Request URL 和 Request Method，如图 4-8 所示。

图 4-8

其中 Request URL 如下。

https://touch.dujia.qunar.com/list?modules=list,bookingInfo,activityDetail&dep=%E6%9D%AD%E5%B7%9E&query=%E5%8E%A6%E9%97%A8%E8%87%AA%E7%94%B1%E8%A1%8C&dappDealTrace=false&mobFunction=%E6%89%A9%E5%B1%95%E8%87%AA%E7%94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&date=&configDepNew=&needNoResult=true&originalquery=%E5%8E%A6%E9%97%A8%E8%87%AA%E7%94%B1%E8%A1%8C&limit=0,32&includeAD=true&qsact=search

这个地址中%开头的字符串是中文编译成的字符串，由于服务器不能识别中文字符，所以必须将中文以某种编码方式编译后才能提交到服务器。也可以通过工具还原编码，笔者自己写的客户端解码工具如图 4-9 所示。

图 4-9

通过该工具还原后的 URL 如下。

https://touch.dujia.qunar.com/list?modules=list,bookingInfo,activityDetail&dep=杭州&query=厦门自由行&dappDealTrace=false&mobFunction=扩展自由行&cfrom=zyx&it=FreetripTouchin&date=&configDepNew=&needNoResult=true&originalquery=厦门自由行&limit=0,32&includeAD=true&qsact=search

经过解码还原后，可以观察到这里使用的是 UTF-8 编码，其中 dep 参数表示出发地（当时笔者在杭州），query 和 originalquery 表示目的地，通过修改这两个参数就可以控制遍历整个平台的自由行产品。

由于这里的目标是获取整个自由行的产品列表，因此还需要获取出发站点的列表，从不同的城市出发，会有不同的产品。

返回自由行的首页，单击搜索框左侧的出发地站点，如图 4-10 所示。

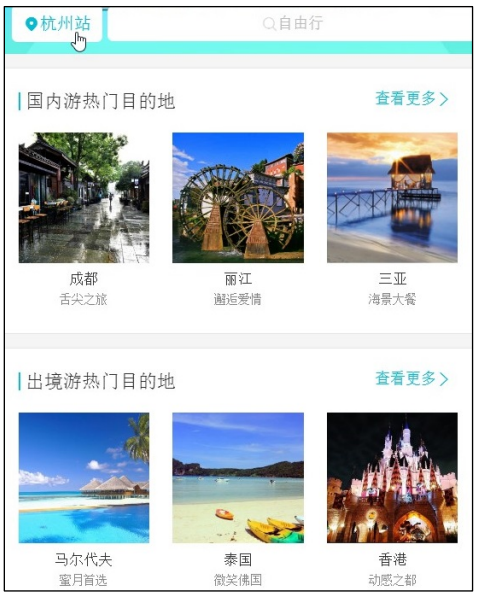

图 4-10

可以看到全国各个出发地站点根据字母排序，在右侧的开发者页面中可以找到对应的数据包，如图 4-11 所示。

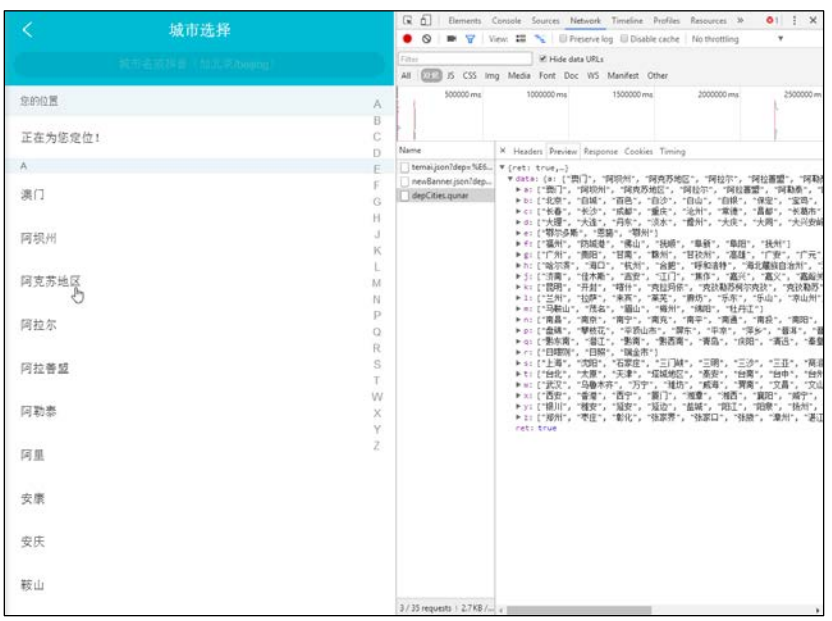

图 4-11

然后切换到 Headers 页面，观察 Request URL 和 Request Method，如图 4-12 所示。

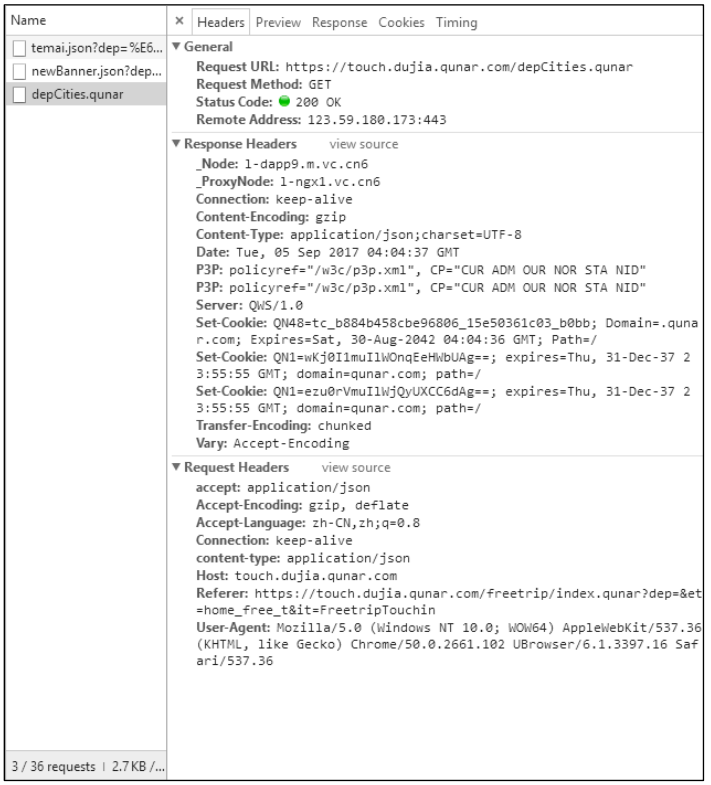

图 4-12

此时的目标 URL 如下。

https://touch.dujia.qunar.com/depCities.qunar

4.2 工作流程分析

通过 4.1 节的解析，接下来实施这个爬虫，步骤如下（参见图 4-13）。

（1）获取出发地站点列表

（2）获取旅游景点列表

（3）获取景点产品列表

（4）存储数据

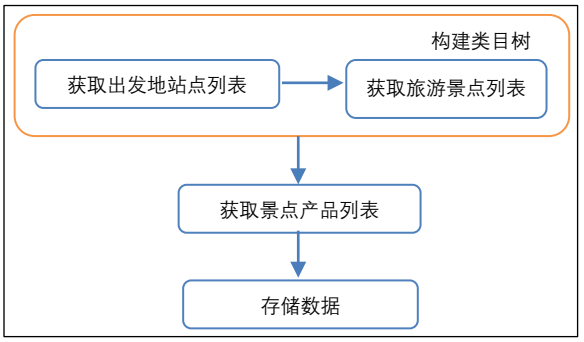

图 4-13

4.3 构建类目树

首先获取出发地站点，输入以下代码。

```
import requests
url='https://touch.dujia.qunar.com/depCities.qunar'
strhtml=requests.get(url)
dep_dict=strhtml.json()
for dep_item in dep_dict['data']:
    for dep in dep_dict['data'][dep_item]:
        print(dep)
```

代码运行结果如图 4-14 所示。

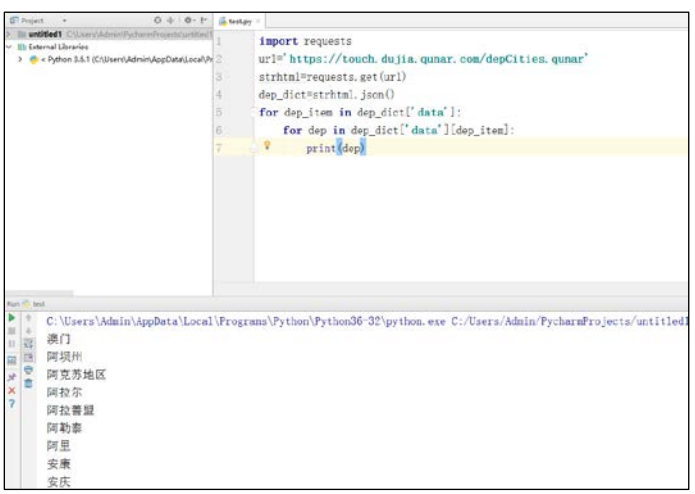

图 4-14

然后根据出发地站点获取目的地，继续输入以下代码。

```
    import requests
    import urllib
    import time
    url='https://touch.dujia.qunar.com/depCities.qunar'
    strhtml=requests.get(url)
    dep_dict=strhtml.json()
    for dep_item in dep_dict['data']:
        for dep in dep_dict['data'][dep_item]:
            print(dep)
            url   =   'https://m.dujia.qunar.com/golfz/sight/arriveRecommend?
dep={}&exclude=&extensionImg=255,175'.format(urllib.request.quote(dep))
            time.sleep(1)
            strhtml = requests.get(url)
            arrive_dict = strhtml.json()
            for arr_item in arrive_dict['data']:
                for arr_item_1 in arr_item['subModules']:
                    for query in arr_item_1['items']:
                        print(query['query'])
```

代码运行结果如图 4-15 所示。

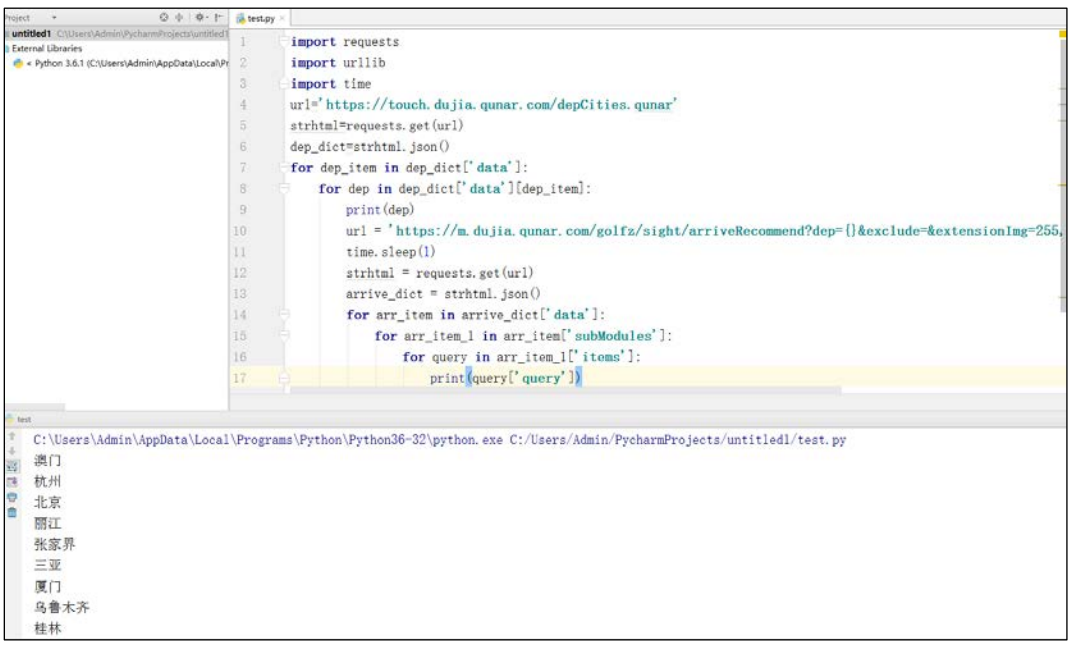

图 4-15

通过观察打印结果，发现目的地有多个重复项（在网页上也可以发现），如果基于这个有重复项的类目树获取数据，会造成资源浪费，因此要先对目的地进行去重。接下来在上一段代码中补充去重的代码（深色底纹的为新增代码）。

```
    import requests
    import urllib
    import time
    url='https://touch.dujia.qunar.com/depCities.qunar'
    strhtml=requests.get(url)
    dep_dict=strhtml.json()
    for dep_item in dep_dict['data']:
        for dep in dep_dict['data'][dep_item]:
            a = []
            print(dep)
            url   =   'https://m.dujia.qunar.com/golfz/sight/arriveRecommend?
dep={}&exclude=&extensionImg=255,175'.format(urllib.request.quote(dep))
            time.sleep(1)
            strhtml = requests.get(url)
            arrive_dict = strhtml.json()
            for arr_item in arrive_dict['data']:
                for arr_item_1 in arr_item['subModules']:
                    for query in arr_item_1['items']:
                        if query['query']  not in a:
                            a.append(query['query'])
            print(a)
```

代码运行结果如图 4-16 所示。

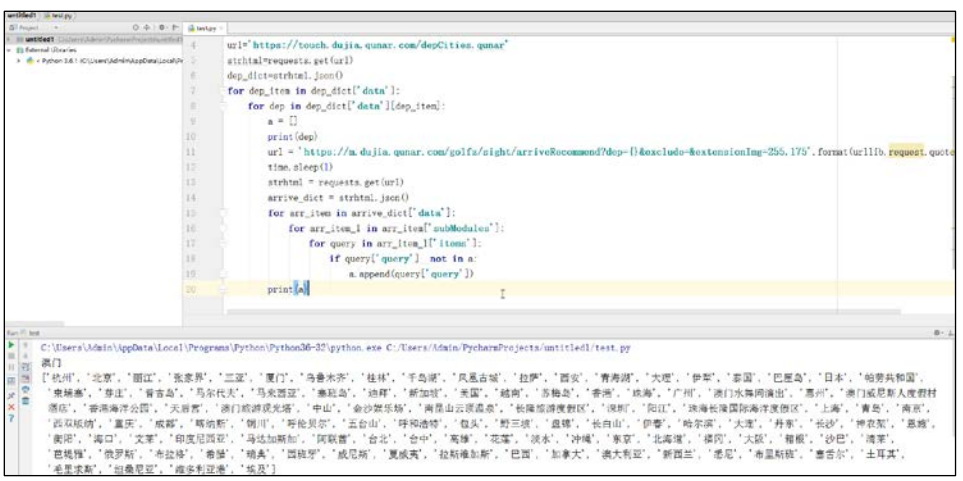

图 4-16

由于去重针对的是每个出发地站点下的目的地，因此需要在获取出发地站点的位置定义一个空的列表 a，每一次循环都会重置 a。

最后判断目的地是否在列表 a 中，如果没有就用 append（合并）方法将目的地加入到列表 a 中，代码如下。

```
    if query['query']  not in a:
    a.append(query['query'])
```

4.4 获取产品列表

完成出发地和目的地的构建后，输入以下代码以便获取产品列表。

```
    import requests
    import urllib
    import time
    import pymongo

    client=pymongo.MongoClient('localhost',27017)
    book_qunar=client['qunar']
    sheet_qunar_zyx=book_qunar['qunar_zyx']
    url='https://touch.dujia.qunar.com/depCities.qunar'
    strhtml=requests.get(url)
    dep_dict=strhtml.json()
    for dep_item in dep_dict['data']:
        for dep in dep_dict['data'][dep_item]:
            a = []
            url   =   'https://m.dujia.qunar.com/golfz/sight/arriveRecommend?
dep={}&exclude=&extensionImg=255,175'.format(urllib.request.quote(dep))
            time.sleep(1)
            strhtml = requests.get(url)
            arrive_dict = strhtml.json()
            for arr_item in arrive_dict['data']:
                for arr_item_1 in arr_item['subModules']:
                    for query in arr_item_1['items']:
                        if query['query']  not in a:
                            a.append(query['query'])
            for item in a:
                url    =    'https://touch.dujia.qunar.com/list?modules=list,
bookingInfo&dep={}&query={}&mtype=all&ddt=false&mobFunction=%E6%89%A9%E5%B1%
95%E8%87%AA%E7%94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&et=FreetripTouch&
date=&configDepNew=&needNoResult=true&originalquery={}&limit=0,20&includeAD=
true&qsact=search'.format(urllib.request.quote(dep),urllib.request.quote(ite
m),urllib.request.quote(item))
```

```
                time.sleep(1)
                strhtml = requests.get(url)
                routeCount=int(strhtml.json()['data']['limit']['routeCount'])
                for limit in range(0, routeCount, 20):
                    url   =   'https://touch.dujia.qunar.com/list?modules=list,
bookingInfo&dep={}&query={}&mtype=all&ddt=false&mobFunction=%E6%89%A9%E5%B1%
95%E8%87%AA%E7%94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&et=FreetripTouch&
date=&configDepNew=&needNoResult=true&originalquery={}&limit={},20&includeAD
=true&qsact=search'.format(
                        urllib.request.quote(dep), urllib.request.quote(item),
                        urllib.request.quote(item),limit)
                    time.sleep(1)
                    strhtml = requests.get(url)
                    result = {
                        'date':  time.strftime('%Y-%m-%d',  time.localtime(time.
time())),
                        'dep': dep,
                        'arrive': item,
                        'limit': limit,
                        'result': strhtml.json()
                    }
                    sheet_qunar_zyx.insert_one(result)
```

代码运行结果如图 4-17 所示。

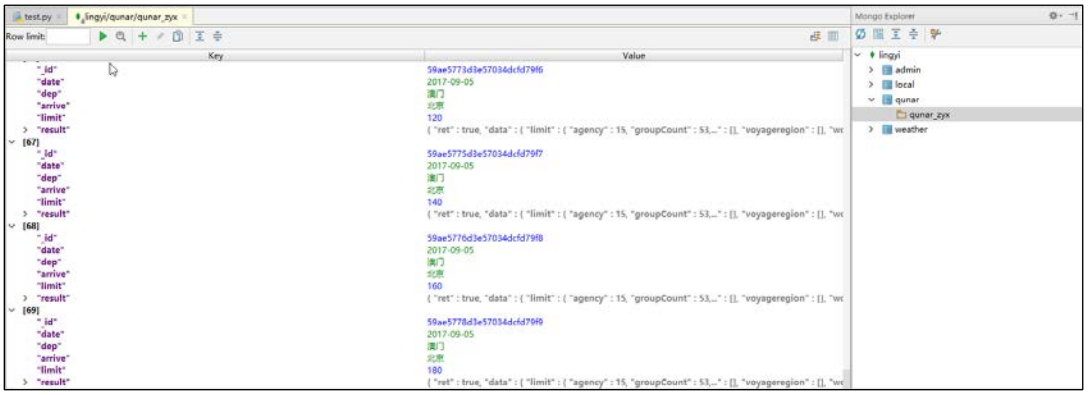

图 4-17

通过观察发现，每个出发地对应的目的地都会有很多个产品，而产品数就在 data.limit.routeCount 键中，如图 4-18 所示。

图 4-18

接下来取出产品数，代码如下。

```
            url     =     'https://touch.dujia.qunar.com/list?modules=list,
bookingInfo&dep={}&query={}&mtype=all&ddt=false&mobFunction=%E6%89%A9%E5%B1%
95%E8%87%AA%E7%94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&et=FreetripTouch&
date=&configDepNew=&needNoResult=true&originalquery={}&limit=0,20&includeAD=
true&qsact=search'.format(urllib.request.quote(dep),urllib.request.quote(que
ry['query']),urllib.request.quote(query['query']))
            time.sleep(1)
            strhtml = requests.get(url)
            routeCount=int(strhtml.json()['data']['limit']['routeCount'])
```

然后，以 routeCount 作为迭代次数的终点，代码如下。

```
    for limit in range(0, routeCount, 20):
```

4.5 代码优化

代码优化可以提高代码的可读性，这里使用 def 自定义函数对本书 4.4 节的代码进行优化。

```
    import requests
    import json
    import urllib.request
    import pymongo
    import time

    client=pymongo.MongoClient('localhost',27017)
    book_qunar=client['qunar']
    sheet_qunar_zyx=book_qunar['qunar_zyx']

    def get_list(dep,item):
        url = 'https://touch.dujia.qunar.com/list?modules=list,bookingInfo&dep
```

```
={}&query={}&mtype=all&ddt=false&mobFunction=%E6%89%A9%E5%B1%95%E8%87%AA%E7%
94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&et=FreetripTouch&date=&configDep
New=&needNoResult=true&originalquery={}&limit=0,20&includeAD=true&qsact=sear
ch'.format(
           urllib.request.quote(dep),
           urllib.request.quote(item), urllib.request.quote(item))
       strhtml = get_json(url)
       routeCount = int(strhtml['data']['limit']['routeCount'])
       for limit in range(0, routeCount, 20):
           url = 'https://touch.dujia.qunar.com/list?modules=list,bookingInfo
&dep={}&query={}&mtype=all&ddt=false&mobFunction=%E6%89%A9%E5%B1%95%E8%87%AA
%E7%94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&et=FreetripTouch&date=&confi
gDepNew=&needNoResult=true&originalquery={}&limit={},20&includeAD=true&qsact
=search'.format(
               urllib.request.quote(dep),
               urllib.request.quote(item),
               urllib.request.quote(item), limit)
           strhtml = get_json(url)
           result = {
               'date': time.strftime('%Y-%m-%d', time.localtime(time.time())),
               'dep': dep,
               'arrive': item,
               'limit': limit,
               'result': strhtml
           }
           sheet_qunar_zyx.insert_one(result)


   def get_json(url):
       strhtml=requests.get(url)
       time.sleep(1)
       return strhtml.json()

   if __name__ == "__main__":

       url='https://touch.dujia.qunar.com/depCities.qunar'
       dep_dict=get_json(url)
       for dep_item in dep_dict['data']:
           for dep in dep_dict['data'][dep_item]:
               a = []
               url =  'https://m.dujia.qunar.com/golfz/sight/arriveRecommend?
dep={}&exclude=&extensionImg=255,175'.format(urllib.request.quote(dep))
               arrive_dict = get_json(url)
               for arr_item in arrive_dict['data']:
```

```
                for arr_item_1 in arr_item['subModules']:
                    for query in arr_item_1['items']:
                        if query['query'] not in a:
                            a.append(query['query'])
            for item in a:
                get_list(dep,item)
```

下面获取网页结果 JSON 作为一个自定义函数，传入参数为 url（要访问的地址），代码如下。

```
    def get_json(url):
        strhtml=requests.get(url)
        time.sleep(1)
        return strhtml.json()
```

下面获取产品列表信息作为一个自定义函数，传入参数为 dep（出发地）和 item（目的地），代码如下。

```
    def get_list(dep,item):
        url  =  'https://touch.dujia.qunar.com/list?modules=list,bookingInfo&
dep={}&query={}&mtype=all&ddt=false&mobFunction=%E6%89%A9%E5%B1%95%E8%87%AA%
E7%94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&et=FreetripTouch&date=&config
DepNew=&needNoResult=true&originalquery={}&limit=0,20&includeAD=true&qsact=s
earch'.format(
            urllib.request.quote(dep),
            urllib.request.quote(item), urllib.request.quote(item))
        strhtml = get_json(url)
        routeCount = int(strhtml['data']['limit']['routeCount'])
        for limit in range(0, routeCount, 20):
            url='https://touch.dujia.qunar.com/list?modules=list,bookingInfo&
dep={}&query={}&mtype=all&ddt=false&mobFunction=%E6%89%A9%E5%B1%95%E8%87%AA%
E7%94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&et=FreetripTouch&date=&config
DepNew=&needNoResult=true&originalquery={}&limit={},20&includeAD=true&qsact=
search'.format(
                urllib.request.quote(dep), urllib.request.quote(item),
                urllib.request.quote(item), limit)
            strhtml = get_json(url)
            result = {
                'date': time.strftime('%Y-%m-%d', time.localtime(time.time())),
                'dep': dep,
                'arrive': item,
                'limit': limit,
                'result': strhtml
            }
            sheet_qunar_zyx.insert_one(result)

    if __name__ == "__main__":
```

```
        url='https://touch.dujia.qunar.com/depCities.qunar'
        dep_dict=get_json(url)
        for dep_item in dep_dict['data']:
            for dep in dep_dict['data'][dep_item]:
                a = []
                url = 'https://m.dujia.qunar.com/golfz/sight/arriveRecommend?
dep={}&exclude=&extensionImg=255,175'.format(urllib.request.quote(dep))
                arrive_dict = get_json(url)
                for arr_item in arrive_dict['data']:
                    for arr_item_1 in arr_item['subModules']:
                        for query in arr_item_1['items']:
                            if query['query'] not in a:
                                a.append(query['query'])
                for item in a:
                    get_list(dep,item)
```

if __name__ == "__main__" 表示如果直接执行某个.py 文件，那么该文件中“__name__ == "__main__"”结果是 True，将执行 if __name__ == "__main__"下面定义的代码块；如果从另外一个.py 文件通过 import 导入该文件，那么__name__的值就是这个.py 文件的名字而不是__main__，将不会执行 if __name__ == "__main__"下面定义的代码块。也就是用户写的脚本模块既可以导入别的模块使用，也可以直接执行该模块。

写好爬虫后，需要一个程序定时监控运行结果，具体步骤如下。

（1）新建一个 Python File，命名为 test2.py，如图 4-19 所示。

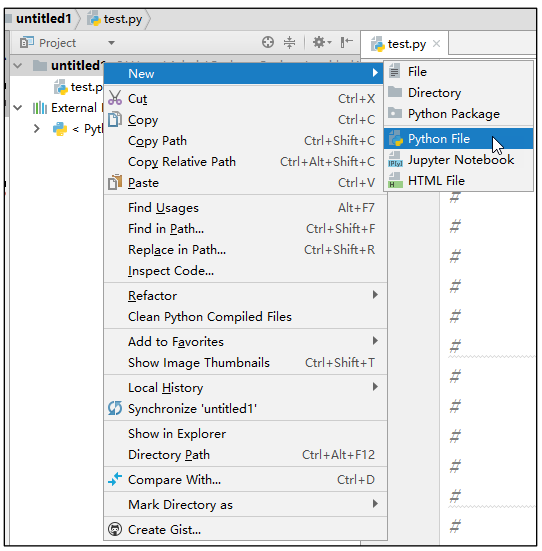

图 4-19

（2）设置为每 10 秒监控一次数据库的记录数，在 test2.py 中输入以下代码。

```
from test import sheet_qunar_zyx
import time

while True:
    print(sheet_qunar_zyx.find().count())
    time.sleep(10)
```

代码运行结果如图 4-20 所示。

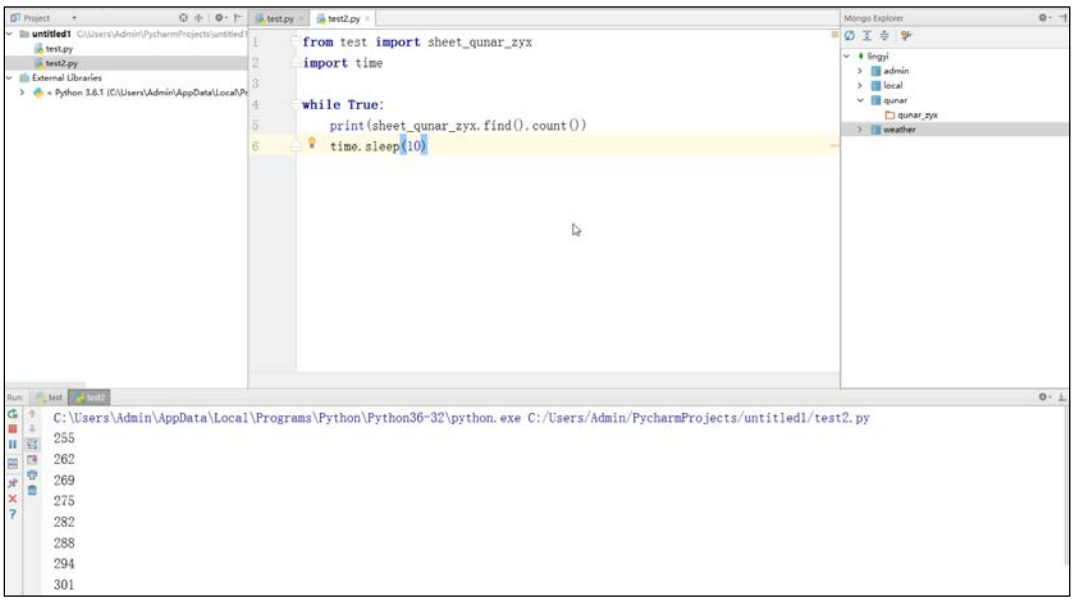

图 4-20

from test import sheet_qunar_zyx 表示从 test.py 文件中调用名为 sheet_qunar_zyx 的对象。需要注意的是，Python 不能读取自定义函数里面的对象，因此在定义 MongoDB 的时候，不能在函数或者子过程中定义。

4.6 爬虫效率优化

本节在 4.5 节的基础上，将爬虫优化成多进程爬虫，以提高爬虫效率。通过之前的爬虫了解到该网站中的出发地共有 700 多个，可以根据出发地同时调用多个 CPU，每个 CPU 运行一个出发地的脚本。笔者的电脑逻辑 CPU 个数是 8，因此每次可以同时获取 8 个出发地的数据。

.py 文件内容、自定义函数，以及将文件命名为 qunar 的相关代码如下。

```
    import requests
    import urllib.request
    import pymongo
    import time

    client = pymongo.MongoClient('localhost', 27017)
    book_qunar = client['qunar']
    sheet_qunar_zyx = book_qunar['qunar_zyx']

    def get_list(dep,item):
        url  =  'https://touch.dujia.qunar.com/list?modules=list,bookingInfo&
dep={}&query={}&mtype=all&ddt=false&mobFunction=%E6%89%A9%E5%B1%95%E8%87%AA%
E7%94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&et=FreetripTouch&date=&config
DepNew=&needNoResult=true&originalquery={}&limit=0,20&includeAD=true&qsact=s
earch'.format(
           urllib.request.quote(dep),
           urllib.request.quote(item), urllib.request.quote(item))
        strhtml = get_json(url)
        routeCount = int(strhtml['data']['limit']['routeCount'])
        for limit in range(0, routeCount, 20):
           url= 'https://touch.dujia.qunar.com/list?modules=list,bookingInfo&
dep={}&query={}&mtype=all&ddt=false&mobFunction=%E6%89%A9%E5%B1%95%E8%87%AA%
E7%94%B1%E8%A1%8C&cfrom=zyx&it=FreetripTouchin&et=FreetripTouch&date=&config
DepNew=&needNoResult=true&originalquery={}&limit={},20&includeAD=true&qsact=
search'.format(
              urllib.request.quote(dep), urllib.request.quote(item),
              urllib.request.quote(item), limit)
           strhtml = get_json(url)
           result = {
              'date': time.strftime('%Y-%m-%d', time.localtime(time.time())),
              'dep': dep,
              'arrive': item,
              'limit': limit,
              'result': strhtml
           }
           sheet_qunar_zyx.insert_one(result)

    def connect_mongo():
        client=pymongo.MongoClient('localhost',27017)
        book_qunar=client['qunar']
        return book_qunar['qunar_zyx']


    def get_json(url):
```

```
        strhtml=requests.get(url)
        time.sleep(1)
        return strhtml.json()

    def get_all_data(dep):
        a = []
        url     =     'https://m.dujia.qunar.com/golfz/sight/arriveRecommend?
dep={}&exclude=&extensionImg=255,175'.format(urllib.request.quote(dep))
        arrive_dict = get_json(url)
        for arr_item in arrive_dict['data']:
            for arr_item_1 in arr_item['subModules']:
                for query in arr_item_1['items']:
                    if query['query'] not in a:
                        a.append(query['query'])
        for item in a:
            get_list(dep,item)

    dep_list = '''
        马鞍山
        茂名
        眉山
        梅州
        惠州
        此处省略 700 多个城市
        葫芦岛
        呼伦贝尔
        湖州
    '''
```

接下来新建一个新的 Python File，命名为 main.py，代码如下。

```
    from qunar import get_all_data      #从 qunar 文件中导入 get_all_data 函数
    from qunar import dep_list          #从 qunar 文件中导入 dep_lista 函数
    from multiprocessing import Pool    #从 multiprocessing 库中导入 Pool 函数

    if __name__ == "__main__":
        pool=Pool()
        pool.map(get_all_data,dep_list.split())
```

多进程爬虫用的库是 Pool（注意输入 Pool 时，第一个字母必须是大写），Pool()函数可以自定义多进程的数量，不设置时代表默认有多少个 CPU 就开多少个进程。

最后使用 pool.map 将第二个参数映射到第一个参数（函数）上。

4.7 容错处理

在代码运行过程中，发现 routeCount 这行语句会出错，经过排查是返回的数据中没有 data.limit.routeCount 这条路径，也就是说对应的出发地和目的地没有产品，因此可以在这条语句加上容错处理，代码如下。

```
try:
    routeCount = int(strhtml['data']['limit']['routeCount'])
except:
    return
```

一旦 routeCount = int(strhtml['**data**']['**limit**']['**routeCount**'])出错，程序就会执行 return，结束当前的 def。

try 完整的结果如下。

```
try:
    ...
except exception1:
    ...
except exception2:
    ...
except:
    ...
else:
    ...
finally:
    ...
```

如果 try 部分没有异常，那么将跳过 except 部分，执行 else 部分的语句。

finally 表示无论是否有异常情况，最后都要执行的语句。

具体流程如下所示。

```
try->异常->except->finally
try->无异常->else->finally
```

第 5 章

Scrapy 爬虫

5.1 Scrapy 简介

谈起爬虫必然要提起 Scrapy 框架，因为它能够帮助提升爬虫的效率，从而更好地实现爬虫。Scrapy 是一个为了抓取网页数据、提取结构性数据而编写的应用框架，该框架是封装的，包含 request（异步调度和处理）、下载器（多线程的 Downloader）、解析器（selector）和 twisted（异步处理）等。对于网站的内容爬取，其速度非常快捷。

也许读者会感到迷惑，有这么好的爬虫框架，为什么前面的章节还要学习使用 requests 库请求网页数据。其实，requests 是一个功能十分强大的库，它能够满足大部分网页数据获取的需求。其工作原理是向服务器发送数据请求，至于数据的下载和解析，都需要自己处理，因而灵活性高；而由于 Scrapy 框架的封装，使得其灵活性降低。至于使用哪种爬虫方式，完全取决于个人的实际需求。在没有明确需求之前，笔者依然推荐初学者先选择 requests 库请求网页数据，而在业务实战中产生实际需求时，再考虑 Scrapy 框架。

5.2 Scrapy 安装

直接使用 pip 安装 Scrapy 会产生一些错误的安装提示信息，导致 Scrapy 无法正常安装。当然，既然有问题出现，必然对应着许多的解决办法。在 http://www.lfd.uci.edu/~gohlke/pythonlibs 网站中，拥有很多适用于 Windows 的、已经编译好的 Python 第三方库，读者只需根据错误的安装提示信息找到相应的包，进行安装即可，此处不对这种方法进行详细讲解。本小节主要介绍如何在 PyCharm 中安装 Scrapy。

第一步，选择 Anaconda 3 作为编译环境。在 PyCharm 中单击左上角 File 选项，单击“Settings”按钮，弹出如图 5-1 所示界面，然后展开 Project Interpreter 的下拉菜单，选择 Anaconda 3 的下拉菜单。

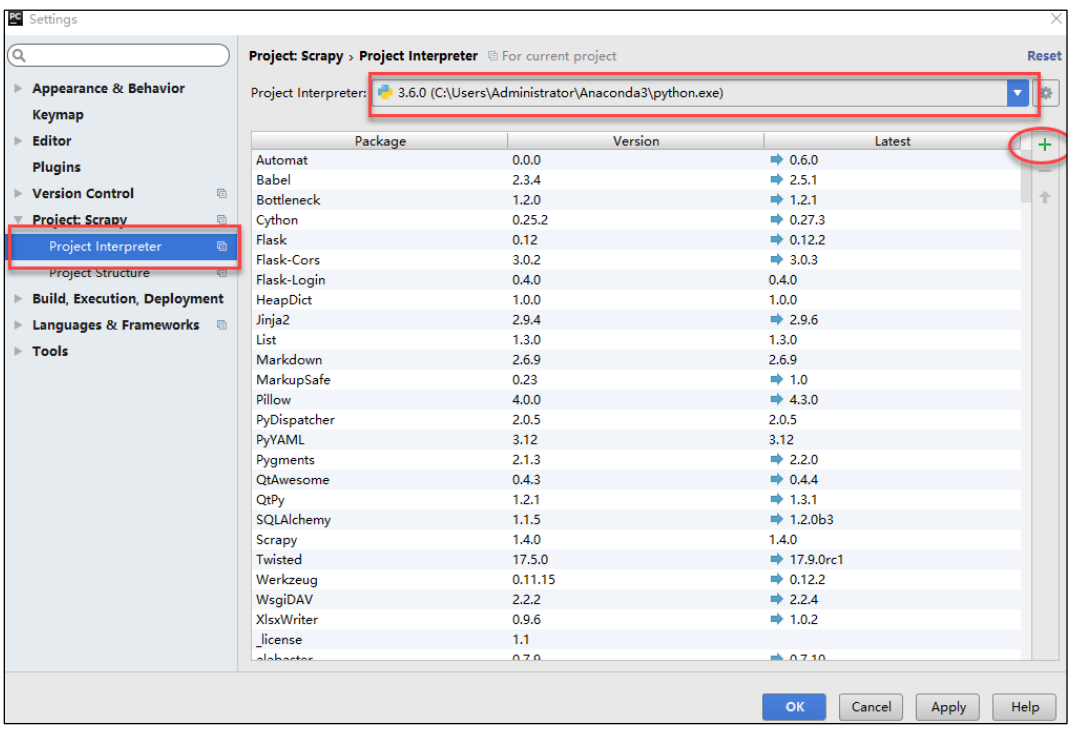

图 5-1

第二步，安装 Scrapy。单击图 5-1 界面右上角绿色加号按钮，弹出如图 5-2 所示的界面。输入并搜索“scrapy”，然后单击“Install Package”按钮。等待，直至出现“Pakage ‘scrapy’ installed successfully”。

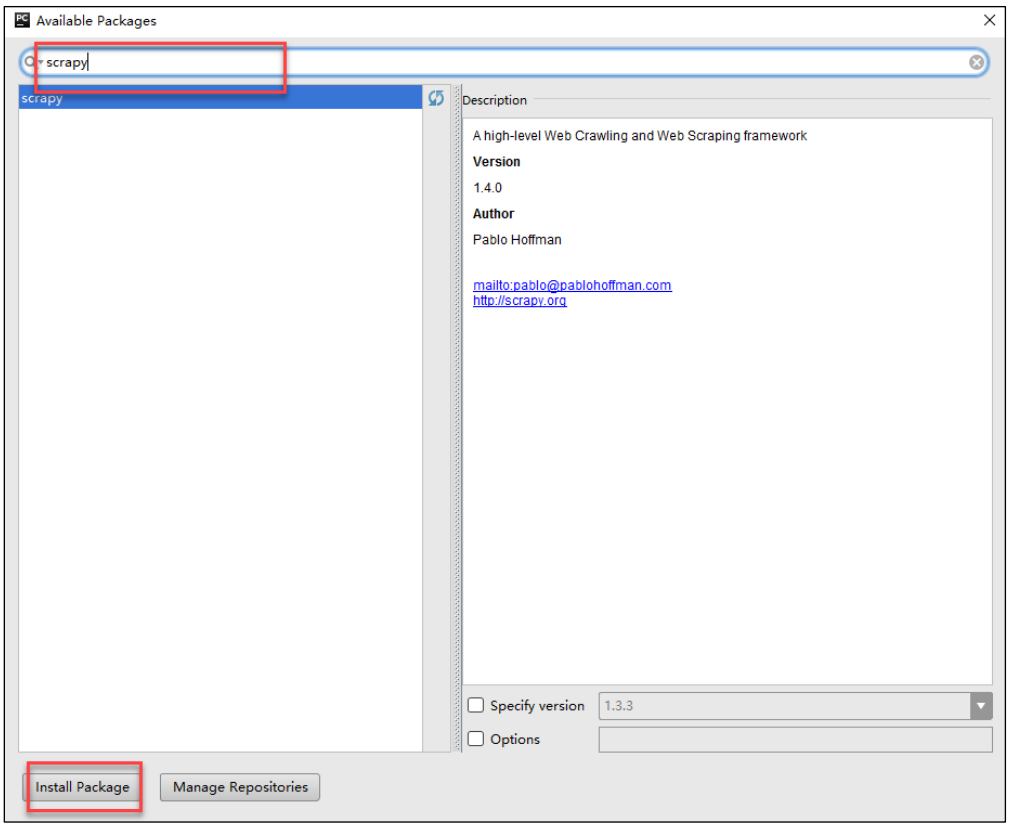

图 5-2

5.3 案例：用 Scrapy 抓取股票行情

本案例将使用 Scrapy 框架，抓取某证券网站 A 股行情，如图 5-3 所示。爬取过程分为以下五步：

第一步，创建 Scrapy 爬虫项目；

第二步，定义一个 item 容器；

第三步，定义 settings 文件进行基本爬虫设置；

第四步，编写爬虫逻辑；

第五步，代码调试。

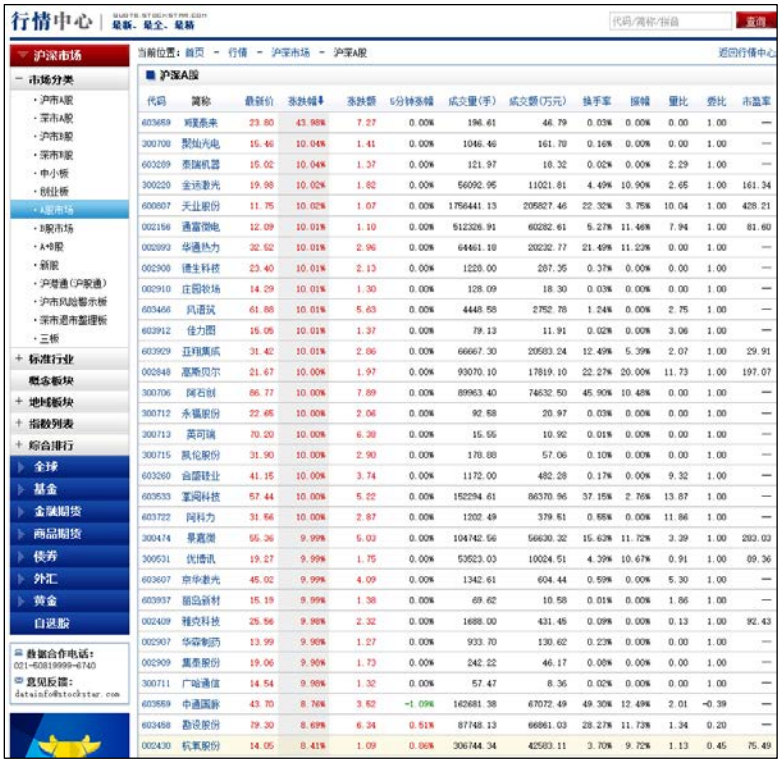

图 5-3

1．创建 Scrapy 爬虫项目

调出 CMD，输入如下代码并按【Enter】键，创建 Scrapy 爬虫项目。

```
scrapy startproject stockstar
```

其中 scrapy startproject 是固定命令，stockstar 是笔者设置的工程名字。

运行上述代码的目的是创建相应的项目文件，如下所示。

放置 spider 代码的目录文件	spiders（用于编写爬虫）。
项目中的 item 文件	items.py（用于保存所抓取的数据的容器，其存储方式类似于 Python 的字典）。
项目的中间件	middlewares .py（提供一种简便的机制，通过允许插入自定义代码来拓展 Scrapy 的功能）。
项目的 pipelines 文件	pipelines.py（核心处理器）。
项目的设置文件	settings.py。
项目的配置文件	scrapy.cfg。

项目结构如图 5-4 所示。

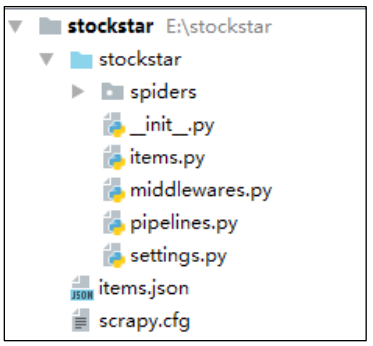

图 5-4

创建 scrapy 项目以后，在 settings 文件中有这样的一条默认开启的语句。

```
ROBOTSTXT_OBEY = True
```

robots.txt 是遵循 Robot 协议的一个文件，在 Scrapy 启动后，首先会访问网站的 robots.txt 文件，然后决定该网站的爬取范围。有时我们需要将此配置项设置为 False 。在 settings.py 文件中，修改文件属性的方法如下。

ROBOTSTXT_OBEY = False

右击 E:\stockstar\stockstar 文件夹，在弹出的快捷菜单中选择“Mark Directory as”命令→选择“Sources Root”命令，这样可以使得导入包的语法更加简洁，如图 5-5 所示。

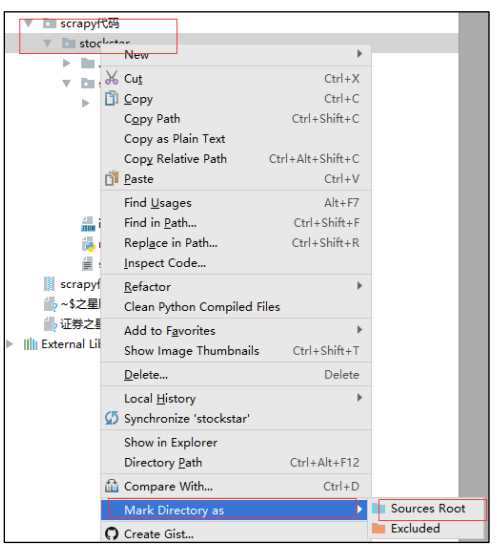

图 5-5

2．定义一个 item 容器

item 是存储爬取数据的容器，其使用方法和 Python 字典类似。它提供了额外的保护机制以避免拼写错误导致的未定义字段错误。

首先需要对所要抓取的网页数据进行分析，定义所爬取记录的数据结构。在相应的 items.py 中建立相应的字段，详细代码如下。

```
    import scrapy
    from scrapy.loader import ItemLoader
    from scrapy.loader.processors import TakeFirst

    class StockstarItemLoader(ItemLoader):
    #自定义 itemloader，用于存储爬虫所抓取的字段内容
        default_output_processor = TakeFirst()

    class StockstarItem(scrapy.Item):# 建立相应的字段
        # define the fields for your item here like:
        # name = scrapy.Field()
        code = scrapy.Field()           # 股票代码
        abbr = scrapy.Field()           # 股票简称
        last_trade = scrapy.Field()     # 最新价
        chg_ratio = scrapy.Field()      # 涨跌幅
        chg_amt = scrapy.Field()        # 涨跌额
        chg_ratio_5min = scrapy.Field() # 5 分钟涨幅
        volumn = scrapy.Field()         # 成交量
        turn_over = scrapy.Field()      # 成交额
```

3．定义 settings 文件进行基本爬虫设置

在相应的 settings.py 文件中定义可显示中文的 JSON Lines Exporter，并设置爬取间隔为 0.25 秒，详细代码如下。

```
        from scrapy.exporters import JsonLinesItemExporter
    # 默认显示的中文是阅读性较差的 Unicode 字符
    # 需要定义子类显示出原来的字符集(将父类的 ensure_ascii 属性设置为 False 即可)
    class CustomJsonLinesItemExporter(JsonLinesItemExporter):
        def __init__(self, file, **kwargs):
            super(CustomJsonLinesItemExporter,  self).__init__(file,  ensure_
ascii=False, **kwargs)
    # 启用新定义的 Exporter 类
    FEED_EXPORTERS = {
        'json': 'stockstar.settings.CustomJsonLinesItemExporter',
    }
    ...
    # Configure a delay for requests for the same website (default: 0)
```

```
    # See http://scrapy.readthedocs.org/en/latest/topics/settings.html#download-
delay
    # See also autothrottle settings and docs
DOWNLOAD_DELAY = 0.25
```

4．编写爬虫逻辑

在编写爬虫逻辑之前，需要在 stockstar/spider 子文件下创建.py 文件，用于定义爬虫的范围，也就是初始 URL。接下来定义一个名为 parse 的函数，用于解析服务器返回的内容。

首先在 CMD 中输入代码，并生成 spider 代码，如下所示。

```
cd stockstar
scrapy genspider stock quote.stockstar.com
```

此时 spider 文件夹下面会创建后缀名为 stock.py 的文件，该文件会生成 start_url，即爬虫的起始地址，并且创建名为 parse 的自定义函数，之后的爬虫逻辑将在 parse 函数中书写。文件详情如图 5-6 所示，代码详情如图 5-7 所示。

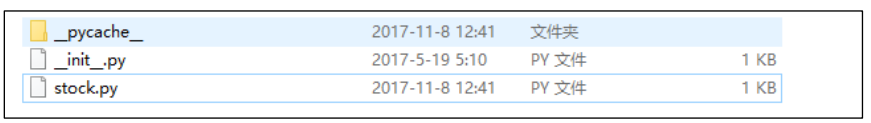

图 5-6

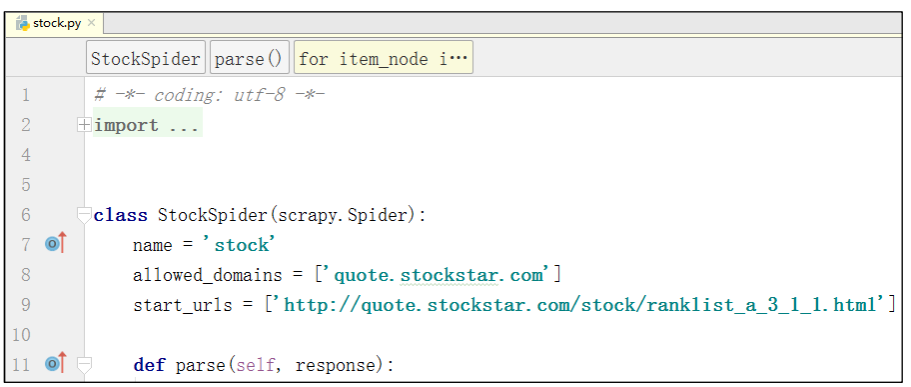

图 5-7

随后在 spiders/stock.py 文件下，定义爬虫逻辑，详细代码如下。

```
import scrapy
from items import StockstarItem, StockstarItemLoader
class StockSpider(scrapy.Spider):
    name = 'stock'                                  #定义爬虫名称
    allowed_domains = ['quote.stockstar.com']  #定义爬虫域
    start_urls = ['http://quote.stockstar.com/stock/
```

```
ranklist_a_3_1_1.html']
            #定义开始爬虫链接
            def parse(self, response):  #撰写爬虫逻辑
            page = int(response.url.split("_")[-1].split(".")[0])  #抓取页码
            item_nodes = response.css('#datalist tr')
            for item_node in item_nodes:
               #根据 item 文件中所定义的字段内容，进行字段内容的抓取
               item_loader = StockstarItemLoader(item=StockstarItem(),
selector = item_node)
               item_loader.add_css("code", "td:nth-child(1) a::text")
               item_loader.add_css("abbr", "td:nth-child(2) a::text")
               item_loader.add_css("last_trade", "td:nth-child(3) span::text")
               item_loader.add_css("chg_ratio", "td:nth-child(4) span::text")
               item_loader.add_css("chg_amt", "td:nth-child(5) span::text")
               item_loader.add_css("chg_ratio_5min", "td:nth-child(6) span::
text")
               item_loader.add_css("volumn", "td:nth-child(7)::text")
               item_loader.add_css("turn_over", "td:nth-child(8)::text")
               stock_item = item_loader.load_item()
               yield stock_item
          if item_nodes:
               next_page = page + 1
               next_url = response.url.replace("{0}.html".format(page), "{0}.
html".format(next_page))
               yield scrapy.Request(url=next_url, callback=self.parse)
```

5. 代码调试

为了调试方便，在 E:\stockstar 下新建一个 main.py，调试代码如下。

```
from scrapy.cmdline import execute
execute(["scrapy", "crawl", "stock", "-o", "items.json"])
```

其等价于在 E:\stockstar 下执行命令“scrapy crawl stock -o items.json”，将爬取的数据导出到 items.json 文件。

```
E:\stockstar>scrapy crawl stock -o items.json
```

在代码里可设置断点（如在 spiders/stock.py 内），然后单击“Run”选项按钮→在弹出的菜单中选择“Debug ‘main’”命令，进行调试，如图 5-8 和图 5-9 所示。

stock.py

```
class StockSpider(scrapy.Spider):
    name = 'stock'
    allowed_domains = ['quote.stockstar.com']
    start_urls = ['http://quote.stockstar.com/stock/ranklist_a_3_1_1.html']

    def parse(self, response):
        page = int(response.url.split("_")[-1].split(".")[0])
        item_nodes = response.css('#datalist tr')

        for item_node in item_nodes:
            item_loader = StockstarItemLoader(item=StockstarItem(), selector=item_node)
            item_loader.add_css("code", "td:nth-child(1) a::text")
            item_loader.add_css("abbr", "td:nth-child(2) a::text")
            item_loader.add_css("last_trade", "td:nth-child(3) span::text")
            item_loader.add_css("chg_ratio", "td:nth-child(4) span::text")
            item_loader.add_css("chg_amt", "td:nth-child(5) span::text")
            item_loader.add_css("chg_ratio_5min", "td:nth-child(6) span::text")
            item_loader.add_css("volumn", "td:nth-child(7)::text")
            item_loader.add_css("turn_over", "td:nth-child(8)::text")
            stock_item = item_loader.load_item()
            yield stock_item
```

图 5-8

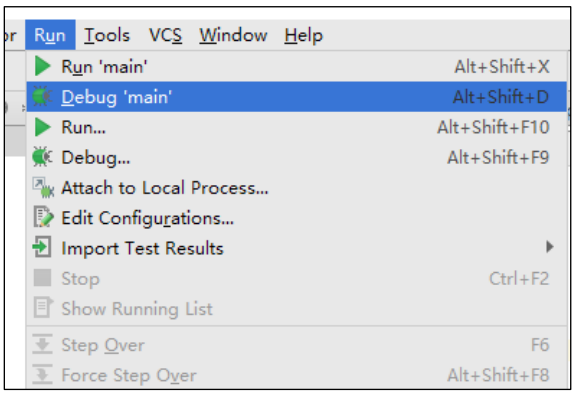

图 5-9

最后在 PyCharm 中运行 Run 'main'，运行界面如图 5-10 所示。

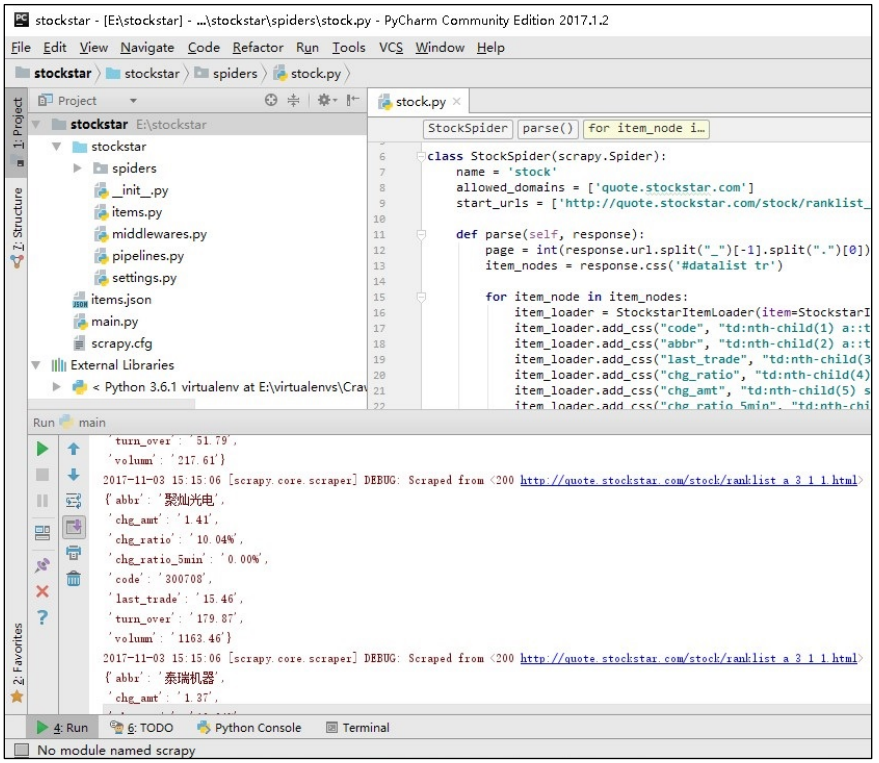

图 5-10

将所抓取的数据以 JSON 格式保存在 item 容器中，如图 5-11 所示。

图 5-11

第 6 章

Selenium 爬虫

6.1 Selenium 简介

用 Python 爬取动态页面时，普通的 requests、urllib2 无法实现。如图 6-1 和图 6-2 所示的某旅游网站自由行路线页面，单击“下一页”按钮时会加载新的内容，而网页 URL 不变（没有传入页码相关的参数），requests、urllib2 无法抓取这些动态加载的内容，此时就需要 Selenium 了。

默认
点评
星级
机酒总价
机酒节省
只看直飞
1/1160
上一页
下一页
单程更自由
价格也很赞！
杭州-丽江 |中国国航+丽江老司机青年旅社(经济型) ¥509起
提供给您的套餐总价中已包含酒店税费，机票机场建设费，燃油费。
杭州-丽江3天2晚 | 入住丽江古城山水桃源客栈 + 长龙航空/首都航空往返机票
丽江古城山水桃源客栈 经济型 4.4分/5分 地图
田园标间 双床 不含早 1间2晚
更多房型(3)
去程 长龙航空 GJ8869 经停 08:50-13:35
回程 首都航空 JD5192 直飞 13:00-16:15
更换机票
¥ 3020 /人
套餐价为您节省 ¥750
查看/预订
套餐包含
往返机票 4张
机建燃油 4份
田园标间 1 间2晚
杭州-丽江3天2晚 | 入住Q居丽江束河听松观云客栈 + 长龙航空/首都航空往返...
Q居丽江束河听松观云客栈 经济型 4.9分/5分 地图
精品标准间 双床 不含早 1间2晚
更多房型(3)
去程 长龙航空 GJ8869 经停 08:50-13:35
回程 首都航空 JD5192 直飞 13:00-16:15
更换机票
¥ 3062 /人
套餐价为您节省 ¥752
查看/预订
套餐包含
往返机票 4张
机建燃油 4份
精品标准间 1 间2晚
杭州-丽江3天2晚 | 入住丽江太和园休闲度假酒店 + 长龙航空/首都航空往返机票
丽江太和园休闲度假酒店 高档型 4.4分/5分 地图
太和标准间 双床 不含早 1间2晚
更多房型(5)
¥ 3104 /人
套餐价为您节省 ¥754
查看/预订

图 6-1

杭州-丽江3天2晚 | 入住丽江王府饭店 + 长龙航空/首都航空往返机票
丽江王府饭店 高档型 4.0分/5分 地图
坐落于位于丽江古城南门，步行可至南门停车场，毗邻四方
豪华标准间(限里特惠)... 双床 不含早 1间2晚
更多房型(5)
去程 长龙航空 GJ8869 经停 08:50-13:35
回程 首都航空 JD5192 直飞 13:00-16:15
更换机票
¥ 3338 /人
套餐价为您节省 ¥754
查看/预订
套餐包含
往返机票 4张
机建燃油 4份
1 间2晚
豪华标...
杭州-丽江3天2晚 | 入住丽江花间堂唯美人文客栈 + 长龙航空/首都航空往返机票
丽江花间堂唯美人文客栈 豪华型 4.6分/5分 地图
位于丽江古城，是丽江古城重点保护民居。该酒店各院地点
精品特色房(大床) 大床 双早 1间2晚
更多房型(3)
去程 长龙航空 GJ8869 经停 08:50-13:35
回程 首都航空 JD5192 直飞 13:00-16:15
更换机票
¥ 3368 /人
套餐价为您节省 ¥746
查看/预订
套餐包含
往返机票 4张
机建燃油 4份
1 间2晚
精品特...
1
2
3
4
...
1160
下一页
最后一页

图 6-2

Selenium 是一个用于 Web 应用程序测试的工具。Selenium 测试直接在浏览器中运行，就像真正的用户在操作一样，其支持的浏览器包括 IE、Chrome、Firefox 等。使用它爬取页面十分方便，只需要按照访问步骤模拟人的操作就可以了，不用担心 Cookie、Session 的处理。它可以帮助你输入账户、密码，然后单击“登录”按钮，也可以单击“下一页”按钮实现自动翻页。以上这些功能在应对一些反爬虫机制时十分有用。

接下来进行具体的操作，首先在 PyCharm 中安装 Selenium 框架，如图 6-3 所示。

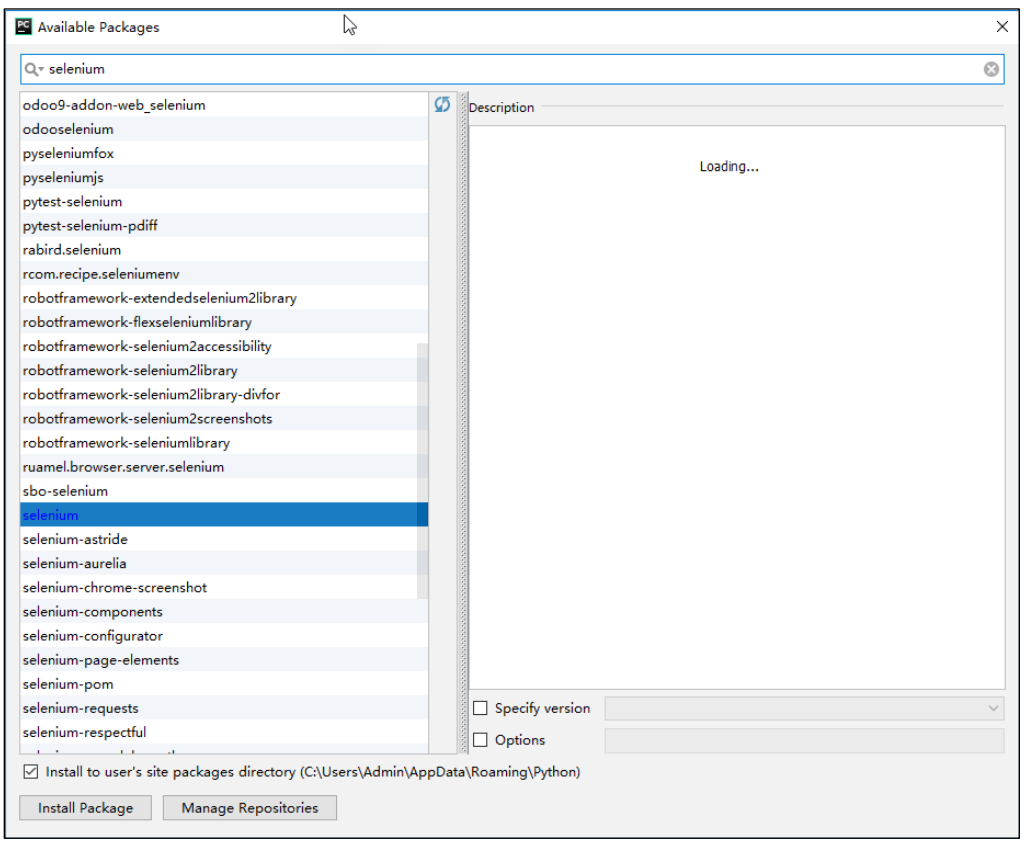

图 6-3

6.2 案例：用 Selenium 抓取电商网站数据

本节案例使用 Selenium 框架，抓取去某电商网站旅游路线数据。

使用 Selenium 需要选择一个调用的浏览器并下载好对应的驱动，在 Windows 桌面可以选择 Chrome、Firefox 等，服务器端可以使用 PhantomJS。桌面版可以直接调出来浏览器观察变化，所以

一般可以通过 Chrome 等调试好桌面版之后，将浏览器改为 PhantomJS，然后上传到服务器使其运行。这里以 Chrome 做演示。

（1）下载谷歌浏览器 Chrome 并安装，下载网址如下。

百度软件中心：http://rj.baidu.com/soft/detail/14744.html?ald

百度云盘：http://pan.baidu.com/s/1geDiMqf

（2）下载浏览器驱动 chromedriver，下载网址如下。

百度云盘：http://pan.baidu.com/s/1bpbD2ZP

将下载的 chromedriver.exe 文件复制到系统路径，例如：

C:\Users\Admin\AppData\Local\Programs\Python\Python36-32\Scripts（安装时已加入环境变量）

如果还没有加入系统变量则可以手工加入。在控制面板中打开“高级系统设置”选项卡→选择“高级”命令→单击“环境变量”按钮，如图 6-4 所示。

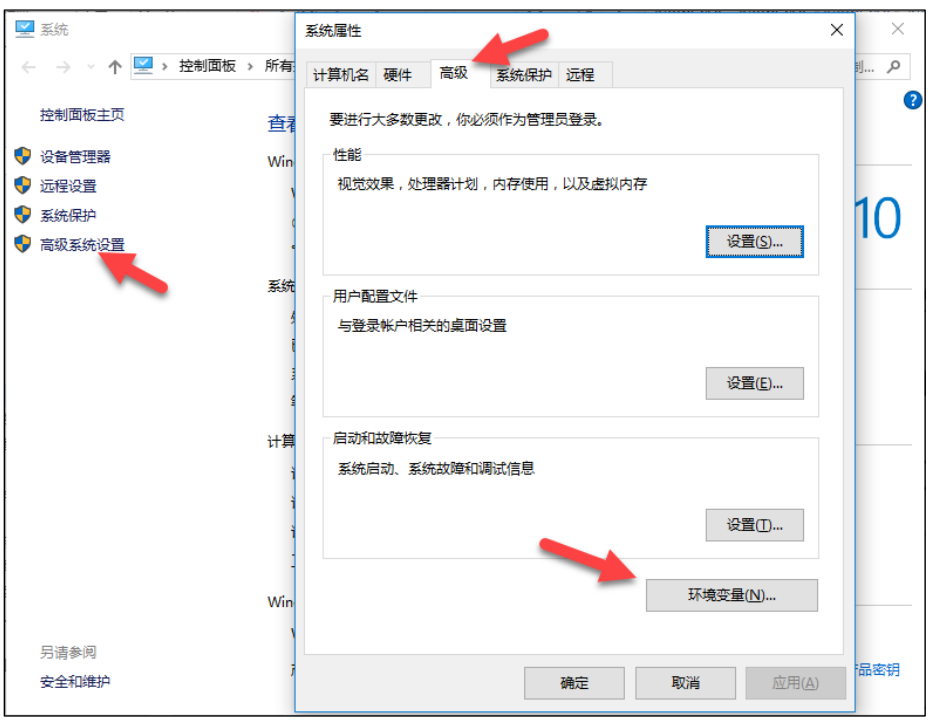

图 6-4

在弹出菜单的系统变量中选择 Path，然后单击右下角的“编辑”按钮，如图 6-5 所示。

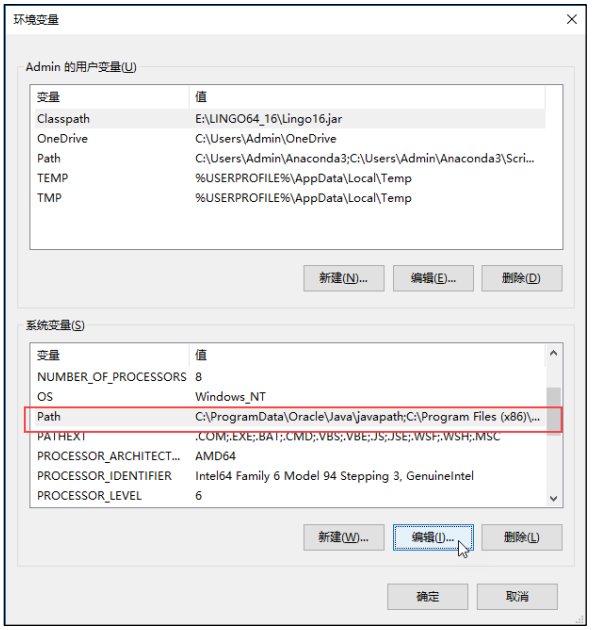

图 6-5

找到 Python 的 Scripts 文件夹目录：路径\ Python\Python 版本号\Scripts，然后单击右侧“新建”按钮，粘贴 Scripts 路径即可，如图 6-6 所示。

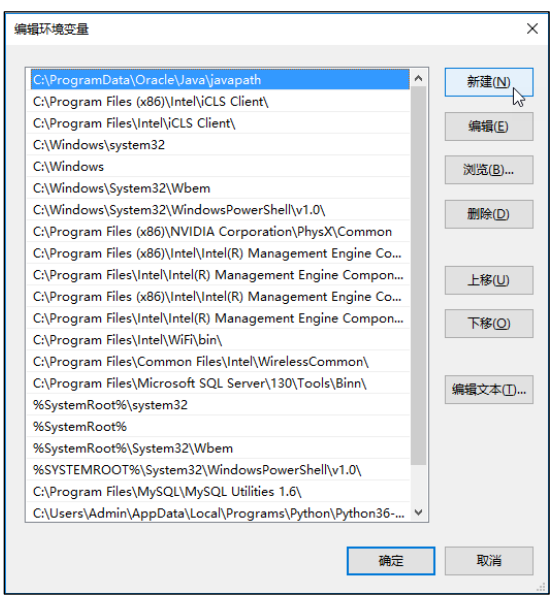

图 6-6

（3）Selenium 爬虫代码实现，输入以下代码。

```
    import requests
    import urllib
    import time
    import random
    from selenium import webdriver
    from selenium.webdriver.common.by import By
    from selenium.webdriver.support.ui import WebDriverWait
    from selenium.webdriver.support import expected_conditions as EC


    def get_url(url):
        time.sleep(5)
        return(requests.get(url))


    if __name__ == "__main__":
        driver = webdriver.Chrome()
    dep_cities = ["北京","上海","广州","深圳","天津","杭州","南京","济南",\
                  "重庆","青岛","大连","宁波","厦门","成都","武汉", "哈尔滨",\
                  "沈阳","西安","长春","长沙","福州","郑州","石家庄","苏州",\
                  "佛山","烟台","合肥","昆明","唐山","乌鲁木齐","兰州",\
                  "呼和浩特","南通","潍坊","绍兴","邯郸","东营","嘉兴","泰州",\
                  "江阴","金华","鞍山","襄阳","南阳","岳阳","漳州","淮安",\
                  "湛江","柳州","绵阳"]
        for dep in dep_cities:
            strhtml = get_url('https://m.dujia.qunar.com/golfz/sight/
arriveRecommend?dep=' + urllib.request.quote(dep) +
'&exclude=&extensionImg=255,175')
            arrive_dict = strhtml.json()
            for arr_item in arrive_dict['data']:
                for arr_item_1 in arr_item['subModules']:
                    for query in arr_item_1['items']:
                        driver.get("https://fh.dujia.qunar.com/?tf=package")
                        WebDriverWait(driver,  10).until(EC.presence_of_element_
located((By.ID, "depCity")))
                        driver.find_element_by_xpath("//*[@id='depCity']").
clear()
                        driver.find_element_by_xpath("//*[@id='depCity']").
send_keys(dep)
                        driver.find_element_by_xpath("//*[@id='arrCity']").
send_keys(query["query"])
                        driver.find_element_by_xpath("/html/body/div[2]/div[1]/
div[2]/div[3]/div/div[2]/div/a").click()
```

```
                    print("dep:%s arr:%s" % (dep, query["query"]))
                    for i in range(100):
                        time.sleep(random.uniform(5, 6))
                        pageBtns = driver.find_elements_by_xpath("html/body/
div[2]/div[2]/div[8]")
                        if pageBtns == []:
                            break
                        routes  =  driver.find_elements_by_xpath("html/body/
div[2]/div[2]/div[7]/div[2]/div")
                        for route in routes:
                            result = {
                                'date': time.strftime('%Y-%m-%d', time.
localtime(time.time())),
                                'dep': dep,
                                'arrive': query['query'],
                                'result': route.text
                            }
                            print(result)

                        if i < 9:
                            btns  =  driver.find_elements_by_xpath("html/body/
div[2]/div[2]/div[8]/div/div/a")
                            for a in btns:
                                if a.text == u"下一页":
                                    a.click()
                                    break

        driver.close()
```

代码运行结果如图 6-7 所示。

调用浏览器对象要用到 Selenium 框架中的 webdriver 库：先初始化一个谷歌浏览器对象，执行以下代码，就可以调用谷歌浏览器，会看到桌面弹出一个浏览器窗口。

```
from selenium import webdriver
driver = webdriver.Chrome()
```

如果要调用火狐浏览器，则用 webdriver.Firefox；如果要调用 PhantomJS 浏览器，则用 webdriver.PhantomJS。

Firefox 驱动下载：http://pan.baidu.com/s/1jHSBK6i

PhantomJS 驱动下载：http://pan.baidu.com/s/1gfnG6sj

接下来通过浏览器打开网页，这里使用 get 方法，代码如下。

```
driver.get("https://fh.dujia.qunar.com/?tf=package")
```

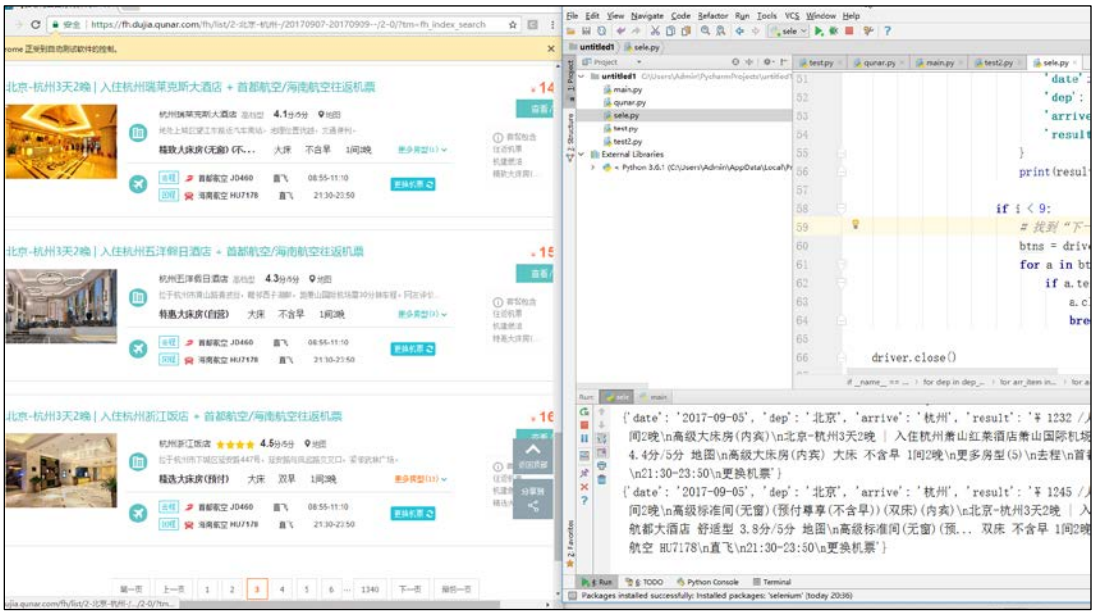

图 6-7

调用浏览器对象要用到 Selenium 框架中的 webdriver 库：先初始化一个谷歌浏览器对象，执行以下代码，就可以调用谷歌浏览器，并看到桌面弹出一个浏览器窗口。

```
from selenium import webdriver
driver = webdriver.Chrome()
```

如果要调用火狐浏览器，则用 webdriver.Firefox；如果要调用 PhantomJS，则用 webdriver.PhantomJS。

Firefox 驱动下载：http://pan.baidu.com/s/1jHSBK6i

PhantomJS 驱动下载：http://pan.baidu.com/s/1gfnG6sj

接下来通过浏览器打开网页，这里使用 GET 方法，代码如下。

```
driver.get("https://fh.dujia.qunar.com/?tf=package")
```

打开网页后，等待出发地输入框加载完毕，如图 6-8 所示。

图 6-8

实现等待需要用到下面三个库：By 库用于指定 HTML 文件中 DOM 标签元素；WebDriverWait 库用于等待网页加载完成；expected_conditions 库（下面用 as EC 作为这个库的简称）用于指定等待网页加载结束的条件。

```
from selenium.webdriver.common.by import By
from selenium.webdriver.support.ui import WebDriverWait
from selenium.webdriver.support import expected_conditions as EC
```

这里的出发地输入框是异步加载的，加载需要等待一段时间，因此需要写一条等待语句。

在浏览器中右击出发地输入框，然后单击菜单中的检查（或者检查元素，不同浏览器的命名不同），会在右侧的开发者模式页面中定位到这个输入框的位置，这个输入框是一个 cinput.textbox 元素，id 是 depCity。接下来等待 id="depCity"的出现，如图 6-9 所示。

图 6-9

使 driver 保持等待，直到读取 id="depCity"，最多等待时间为 10 秒。用 WebDriverWait 指定等待的浏览器和最长等待时间的语句如下。

```
    WebDriverWait(driver,    10).until(EC.presence_of_element_located((By.ID,
"depCity")))
```

其中 EC.presence_of_element_located 用于指定标志等待结束的 DOM 元素，EC.presence_of_element_located 中的(By.ID, "depCity")相当于指定了 id="depCity"。

等待出发地输入框加载完成后，找到输入框的位置，并清除输入框中的数据。

然后右击右侧高亮的代码，在弹出的菜单中选择“Copy”→“Copy XPath”命令，如图 6-10 所示。这里复制得到的 XPath 是//*[@id="depCity"]，它是一个定位用的路径，后面用同样的方法复制目的地输入框和开始定制按钮的 XPath 路径。

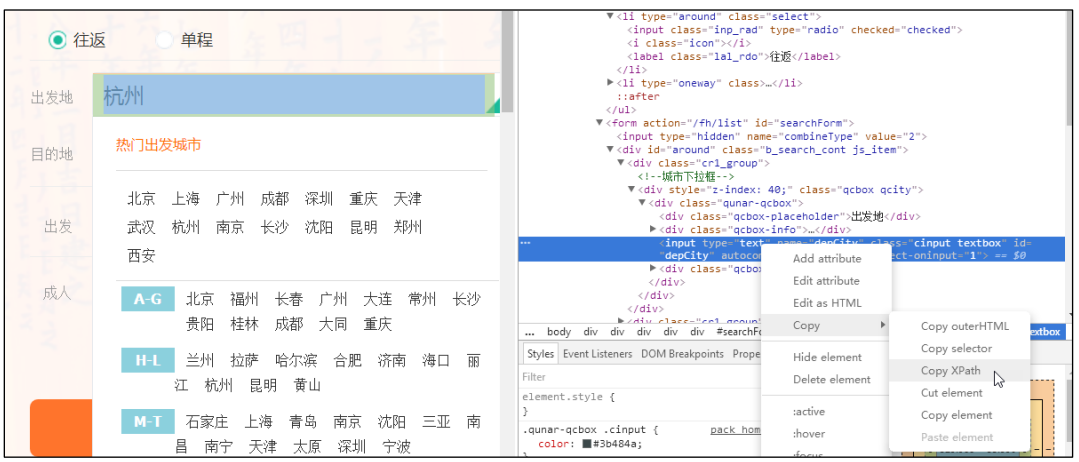

图 6-10

用 webdriver.Chrome()的 find_element_by_xpath（基于 XPath 路径查找元素）方法找到出发地输入框，然后清除输入框的内容，代码如下。

```
    driver.find_element_by_xpath("//*[@id='depCity']").clear()
```

然后将自定义的出发地填入出发地输入框，代码如下。

```
    driver.find_element_by_xpath("//*[@id='depCity']").send_keys(dep)
```

同理，将目的地填入目的地输入框，代码如下。

```
    driver.find_element_by_xpath("//*[@id='arrCity']").send_keys(query["quer
y"])
```

单击页面上的“开始定制”按钮，代码如下。

```
    driver.find_element_by_xpath("/html/body/div[2]/div[1]/div[2]/div[3]/div
/div[2]/div/a").click()
```

接下来定位到搜索结果页的页码按钮，如果定位不到则表示结果为空，跳出循环，代码如下。

```
    pageBtns = driver.find_elements_by_xpath("html/body/div[2]/div[2]/div[8]")
    if pageBtns == []:
        break
```

代码运行结果如图 6-11 所示。

（a）

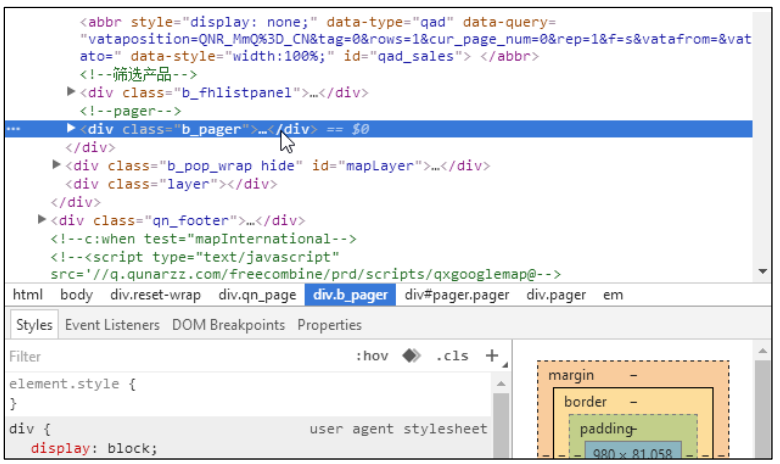

（b）

图 6-11

找到对应的数据，然后分块取出数据，代码如下。

```
    routes = driver.find_elements_by_xpath("html/body/div[2]/div[2]/div[7]/
div[2]/div")
    for route in routes:
        result = {
            'date': time.strftime('%Y-%m-%d', time.localtime(time.time())),
            'dep': dep,
            'arrive': query['query'],
            'result': route.text
        }
```

代码运行结果如图 6-12 所示。

（a）

（b）

图 6-12

接下来指定页码和翻页，这里设定 10 页，检测不到下一页元素就跳出循环，代码如下。

```
    for i in range(10):
        ……
        if i < 9:
        btns = driver.find_elements_by_xpath("html/body/div[2]/div[2]/div[8]/
div/div/a")
        for a in btns:
            if a.text == u"下一页":
                a.click()
                break
```

第 7 章

数据库连接和查询

7.1 使用 PyMySQL

SQL，即结构化查询语言（Structured Query Language），它是一种功能齐全的数据库语言。

7.1.1 连接数据库

下面对 PyMySQL 库进行简要说明。

pymysql.Connect()参数说明如下。

- host(str): MySQL 服务器地址
- port(int): MySQL 服务器端口号
- user(str): 用户名
- passwd(str): 密码
- db(str): 数据库名称
- charset(str): 连接编码

连接代码如下。

加载库：import pymysql

```
import pymysql

db = pymysql.Connect(
    host="localhost",
    port=3306,
    user="root",
    password="12345",
    db="taobao",
    charset="utf8"
)
```

基础操作：增加、删除、修改、查询。

首先介绍 connection 对象和 cursor 对象支持的方法。

connection 对象支持的方法如下。

- cursor()　　使用该连接创建并返回游标。
- commit()　　提交当前事务。
- rollback()　　回滚当前事务。
- close()　　关闭连接。

cursor 对象支持的方法如下。

- execute(op)　　执行一个数据库的查询命令。
- fetchone()　　取得结果集的下一行。
- fetchmany(size)　　获取结果集的下几行。
- fetchall()　　获取结果集中的所有行。
- rowcount()　　返回数据条数或影响行数。
- close()　　关闭游标对象。

（1）向数据库新增数据

SQL 语法：

```
insert into table_name (column1, column2,...,columnN)
values(value1,value2,...,valueN)
```

Python 语法：

```
op = "insert into table_name (column1, column2,...,columnN)
values(value1,value2,...,valueN)"
cursor.execute(op)
```

（2）删除数据库中的数据

SQL 语法：

```
delete from table_name where condition_statement
```

Python 语法：

```
op = "delete from table_name where condition_statement"
cursor.execute(op)
```

（3）修改数据库中的数据

SQL 语法：

```
update table_name set column1= value1, column2=value2,...,columnN=valueN
where condition_statement
```

Python 语法：

```
op = "update table_name set column1= value1, column2=value2, ...,columnN=valueN
where condition_statement"
cursor.execute(op)
```

（4）查询数据库中的数据

SQL 语法：

```
select * from table_name where condition_statement
```

Python 语法：

```
op = "select * from table_name where condition_statement"
cursor.execute(op)
```

7.1.2 案例：某电商网站女装行业 TOP100 销量数据

（1）首先用 Nvicat for MySQL 导入向导把 sale_data.txt 导入数据库 taobao，导入结果如图 7-1 所示。

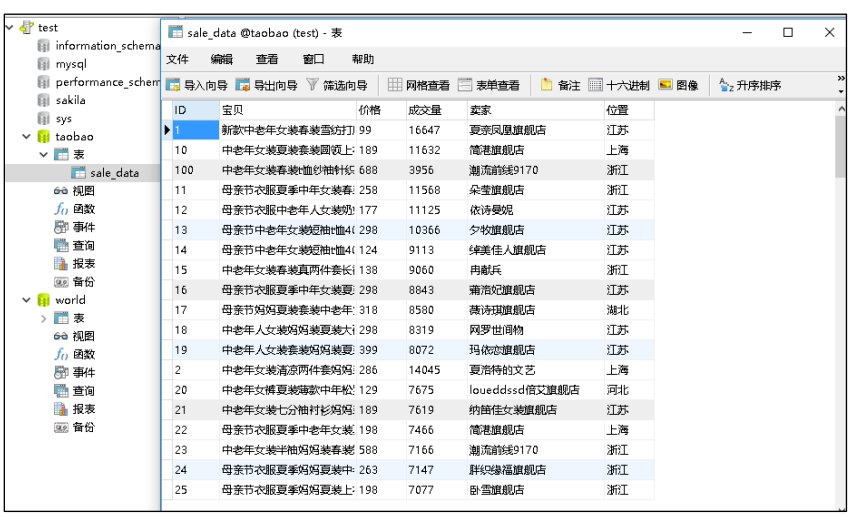

图 7-1

修改表设计，把 ID 改为自动递增，如图 7-2 所示。

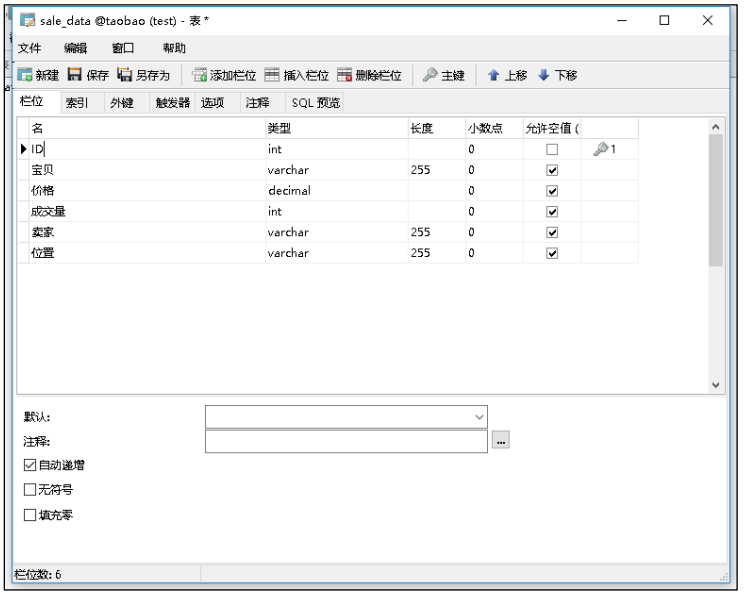

图 7-2

（2）连接数据库，代码如下。

```
import pymysql

db = pymysql.Connect(
    host="localhost",
    port=3306,
    user="root",
    password="12345",
    db="taobao",
    charset="utf8"
)
```

（3）查询位置在江浙沪的商品销量，代码如下。

```
# 获取游标
cur = db.cursor()

# 执行 SQL 语句，进行查询
sql = 'SELECT * FROM sale_data WHERE 位置 IN (%s,%s,%s)'
cur.execute(sql, ("江苏", "浙江","上海"))

# 获取查询结果
```

```
    result = cur.fetchall()

    for item in result:
        print(result)
```

（4）删除价格低于 100 元的商品记录，代码如下。

```
    # 执行 SQL 语句，进行删除
    sql = 'DELETE FROM sale_data WHERE 价格 < 100'
    cur.execute(sql)

    # 没有设置默认自动提交，需要主动提交，以保存所执行的语句
    db.commit()
```

（5）把位置“江苏”“浙江”“上海”统一改为“江浙沪”，代码如下。

```
    # 执行 SQL 语句，进行修改
    sql = 'UPDATE sale_data SET 位置 = %s WHERE 位置 IN (%s,%s,%s)'
    cur.execute(sql, ("江浙沪","江苏","浙江","上海"))

    # 没有设置默认自动提交，需要主动提交，以保存所执行的语句
    db.commit()
```

（6）插入一条新的销售记录，代码如下。

```
    # 执行 SQL 语句，进行插入操作
    sql = 'INSERT INTO sale_data(商品,价格,成交量,卖家,位置) VALUES(%s, %s,%s,%s,%s)'
    cur.execute(sql, ("2017 夏季妈妈装 40-50 岁中老年女装连衣裙",298,10000,"XXX 天猫旗舰店","北京"))

    # 没有设置默认自动提交，需要主动提交，以保存所执行的语句
    db.commit()
```

（7）关闭游标和数据库连接，代码如下。

```
    cur.close()
    db.close()
```

7.2 使用 SQLAlchemy

7.2.1 SQLAlchemy 基本介绍

SQLAlchemy 是 Python 用来操作数据库的一个库，该库提供了 SQL 工具包及对象关系映射（ORM）工具。数据库中的记录用 Python 的数据结构来表现，可以看作一个列表，每条记录是列表

中一个元组，如产品信息表中便包含了列名“ID”、“name”和“type”，如下所示。

```
    [
    ("19558276","北京 5 天 4 晚自由行 含双早 入住前门商业街豪华酒店 含双人故宫电子门票",
“景+酒"）
    ("20235858","北京 3 日自由行(5 钻)·昆仑饭店 三里屯商圈 周末低价 不含交通","本地游"）
    ("20373502","北京+古北水镇 3 日自由行·国都大饭店+5 星古北之光 [含水镇门票+温泉]","
本地游"）
    ]
```

但是仅通过一个元组很难看出表的结构，如果把一个元组用一个类（class）来表示，则很容易看出表的结构，代码如下。

```
    class Product (object):
        def __init__(self,ID, name, type):
            self.ID = ID
            self.name = name
            self.class_name = type

    [
    Product("19558276","北京 5 天 4 晚自由行 含双早 入住前门商业街豪华酒店 含双人故宫电
子门票","景+酒"),
    Product ("20235858","北京 3 日自由行(5 钻)·昆仑饭店 三里屯商圈 周末低价 不含交通","
本地游"),
    Product ("20373502","北京+古北水镇 3 日自由行·国都大饭店+5 星古北之光 [含水镇门票+
温泉]","本地游")
    ]
```

这就是 ORM（Object-Relational Mapping)技术，该技术把关系型数据库映射到对象上。

在 Python 中，最主流的 ORM 框架是 SQLAlchemy，使用前需要在 Pycharm 中安装 SQLAlchemy 库。

7.2.2　SQLAlchemy 基本语法

（1）导入 SQLAlchemy，并初始化 DBSession。

```
    # 导入:
    from sqlalchemy import Column, String, create_engine
    from sqlalchemy.orm import sessionmaker
    from sqlalchemy.ext.declarative import declarative_base
    # 创建对象的基类:
    Base = declarative_base()
    # 定义 Product 对象:
    class Product(Base):
        # 表的名字:
```

```
    __tablename__ = 'Product'
    # 表的结构:
    ID = Column(String(20), primary_key=True)
    name = Column(String(20))
    class_name = Column(String(20))
        # 初始化数据库连接:
        engine = create_engine('mysql+pymysql://root:password@localhost:
        3306/test')
        # 创建 DBSession 类型
        DBSession = sessionmaker(bind=engine)
```

其中 create_engine()用来初始化数据库连接。SQLAlchemy 用一个字符串表示连接信息，代码如下。

```
'数据库类型+数据库驱动名称://用户名:口令@机器地址:端口号/数据库名'
```

这时只需要根据需要替换掉这里的用户名、口令等信息即可。

（2）向数据库表中添加一行记录。

```
    # 创建 session 对象:
    session = DBSession()
    # 创建新 Product 对象:
    new_user = Product(ID='19558276', name='北京 5 天 4 晚自由行 含双早 入住前门商业
街豪华酒店 含双人故宫电子门票', type='景+酒')
    # 添加到 session:
    session.add(new_user)
    # 提交即保存到数据库:
    session.commit()
```

其中 DBSession 对象可视为当前数据库连接。

（3）从数据库表中查询数据。

```
    # 创建 Query 查询，filter 是 where 条件，最后调用 one()返回唯一行，如果调用 all()则返
回所有行
    student = session.query(Product).filter(Product.ID=='19558276').one()
    # 打印对象的 name,class_name 属性
    print('name:', student.name)
    print('class_name:', student.class_name)
```

（4）在数据库表中更新数据。

```
    # 查询并更新数据
    session.query(Product).filter(Product.ID=='19558276').update({Product.na
me:"北京 5 天 4 晚自由行，景+酒套餐"})
    # 提交即保存到数据库:
    session.commit()
```

（5）从数据库表中删除数据。

```
# 查询并删除数据
session.query(Product).filter(Product.ID=='19558276').delete()
# 提交即保存到数据库:
session.commit()
# 最后关闭 Session:
session.close()
```

7.3 MongoDB

7.3.1 MongoDB 基本语法

加载库：import pymongo

必须在已经完成本地 MongoDB 服务器的安装和启动的前提下，才能继续操作。

首先进入安装路径，代码如下。

```
C:\\Users\Administrator>cd C:\\Program Files\\MongoDB\Server\3.2\bin
```

然后启动命令，代码如下。

```
C:\Users\Administrator>cd C:\Program Files\MongoDB\Server\3.2\bin
```

- 建立连接

```
client=pymongo.MongoClient('localhost',27017)
```

- 新建数据库

```
db=client["db_name"]
```

- 新建表

```
table=db["table_name"]
```

- 写入数据

```
table.insert({"key1":value1,"key2":value2})
```

- 删除数据

```
table.remove({"key":value})
```

- 修改数据

```
table.update({"key":value},{"$set":{"key1":value1,"key2":value2}})
```

- 查询数据

```
table.find({"key":value})
```

7.3.2 案例：在某电商网站搜索“连衣裙”的商品数据

（1）将某电商网站搜索“连衣裙”的第一页商品数据抓取下来并存入 MongoDB 数据库。

```
    import requests
    import pymongo

    client=pymongo.MongoClient('localhost',27017)
    #新建数据库
    taobao=client['taobao']
    #新建表
    search_result=taobao['search_result']

    #爬取某电商网站商品数据
    url='https://s.m.taobao.com/search?q=%E8%BF%9E%E8%A1%A3%E8%A3%99&search=
%E6%8F%90%E4%BA%A4&tab=all&sst=1&n=20&buying=buyitnow&m=api4h5&abtest=24&wls
ort=24&page=1'
    strhtml=requests.get(url)
    result= strhtml.json()

    for item in result['listItem']:
        json_data = {
            'title':item['title'],
            'price': float(item['price']),
            'sold':int(item['sold']),
            'location': item['location']
        }
    #写入数据
    search_result.insert(json_data)
```

（2）查询位置在“浙江 杭州”，并且价格大于 100 元的商品数据。

```
    for item in search_result.find({"location": "浙江 杭州", "price":
{'$gt':100}}):
    print (item)
```

（3）将位置“浙江 杭州”改为“浙江”。

```
    search_result.update({"location": "浙江 杭州"},{"$set":{"location": "浙江
"}})
```

（4）删除销量小于 1000 件的商品数据。

```
    search_result.remove({"sold": {'$lt':1000}})
```

第 8 章

NumPy

8.1 NumPy 简介

NumPy 是 Numerical Python 的简称，是高性能计算和数据分析的基础包。虽然 Python 是用于通用编程的优秀工具，具有高度可读的语法和丰富强大的数据类型（字符串、列表、集合、字典和数字等），以及非常全面的标准库，特别是 Python 列表。它是非常灵活的容器，可以任意深度嵌套，并且可以容纳任何 Python 对象，但它并不是专为数学和科学计算而设计的，难以有效地表示常用的数学结构（向量和矩阵）。其语言和标准库中都没有用于多维数据集高效表示的工具、线性代数工具和一般矩阵操作工具（实际上是所有技术计算的基本组成部分）。精通数组的思维，掌握面向数组的编程，将会为你的 Python 生涯奠定坚实的根基。其实 NumPy 本身并没有很多高级数据分析的功能，而 pandas 却能够使得数据分析变得便捷，因此很多人都选择将 pandas 作为数据分析的基础。当然，如果仅仅是做一些基本的数据预处理的话，那么直接跳过本章，直接学习第 9 章即可。

8.2 一维数组

8.2.1 数组与列表的异同

首先用熟悉的列表对比陌生的数组，进而初步认识什么是数组。进入 IPython Jupyter，导入 NumPy，创建一个列表和一个数组，代码如下。

```
import numpy as np
LIST = [1, 3, 5, 7]
ARR = np.array([1, 3, 5, 7])
type(ARR)
```

输出结果为 numpy.ndarray。

接下来了解列表索引与数组索引，编写代码访问数组中的元素。

LIST[0]，输出结果为 1。

ARR[0]，输出结果为 1。

ARR[2:]，输出结果为 array([5, 7])。

从上述例子中可以发现列表与数组有着相同的元素和相同的索引机制，为什么 Python 还需要创建一个 NumPy 包？列表和数组的区别究竟是什么？列表和数组之间的首要区别：数组是同类的;，即数组的所有元素必须具有相同的类型。相反，列表可以包含任意类型的元素，例如可以将上面列表中的最后一个元素更改为一个字符串。

```
LIST[-1] = 'string'
```

输出结果为[1, 3, 5, 'string']。

```
ARR[-1] = 'string'
```

而输出上述代码会报错，报错原因是元素无效，如图 8-1 所示。

```
ARR[-1] = 'string'
---------------------------------------------------------------------------
ValueError                                Traceback (most recent call last)
<ipython-input-8-d41951952b1f> in <module>()
----> 1 ARR[-1] = 'string'

ValueError: invalid literal for int() with base 10: 'string'
```

图 8-1

也就是说一旦创建了一个数组，那么它的 dtype 也就固定了，它只能存储相同类型的元素。如何确定数组内的数据类型以保证正确的数据格式？其实有关数组类型的信息均包含在数组的 dtype 属

性中。接下来访问数组元素的数据类型，代码如下。

```
ARR.dtype
#输出结果为：dtype('int32')。
```

上述结果显示 ARR 数组中的数据类型为整数类型。为整数类型数组中添加字符串，系统会因无法识别该数据类型而报错。那么如果存储一个浮点数类型，结果会如何？事实证明，当存储一个浮点数类型时，系统会自动将其转化为整数类型，代码如下。

```
ARR[-1] = 1.234
#输出结果为 array([10, 20, 30, 1])。
```

8.2.2 数组的创建

在 8.2.1 节中，我们从现有的列表中创建了一个数组，接下来学习创建数组的其他方式。在创建数组的时候，通常用一个常量值（一般为 0 或 1）初始化一个数组，这个值通常是作为加法和乘法循环的起始值，创建示例代码如下。

```
np.zeros(5, dtype=float)
#输出结果为：array([ 0.,  0.,  0.,  0.,  0.])。这里创建了浮点数类型的值全为 0 的数组
np.zeros(3, dtype=int)
#输出结果为：array([0, 0, 0])。这里创建了整数类型的值全为 0 的数组
np.ones(5)
#输出结果为：array([ 1.,  1.,  1.,  1.,  1.])。这里创建了值全为 1 的数组
#如果想要以任意值作为初始化的数组，那么可以创建一个空数组，然后使用 fill 方法将想要的值放入数组中，如下所示
a = np.empty(4)
#产生的值都是空值
a.fill(5.5)
#填充值为 5.5
#输出结果为：array([ 5.5,  5.5,  5.5,  5.5])
```

最后，创建常用的随机数字的数组。在 NumPy 中，np.random 模块包含许多可用于创建随机数组的函数，例如生成一个服从标准正态分布（均值为 0 和方差为 1）的 5 个随机样本数组，代码如下。

```
np.random.randn(5)
#输出结果为：array([-0.14526131,  0.47733858,  1.44428435, -2.2223782 , 1.02561916])
```

8.3 多维数组

8.2 节示例使用的是一维数组，所提到的与列表相同的索引机制，也指的是一维数组。其实 NumPy 可以创建 N 维数组对象（ndarray），这也是 NumPy 的一个关键特性。ndarray 是一种快速并且节省空

间的多维数组，它可以提供数组化的算术运算和高级的广播功能。通过使用标准的数学函数，并不需要编写循环，便可以对整个数组的数据进行快速的运算。除此之外 ndarray 还具备线性代数，随机数生成，和傅里叶变换的能力。总而言之，ndarray 是 Python 中的一个具有计算快速、灵活等特性的大型数据集容器。当然，在 8.2 节中介绍的所有方法都可以处理多个维度。例如可以使用列表来初始化一个二维数组：

```
LIST2 = [[1, 2], [3, 4]]
ARR2 = np.array([[1, 2], [3, 4]])
#输出结果为：array([[1, 2],
#                   [3, 4]])
```

接下来就使用二维数组，感受下 NumPy 的强大功能。

8.3.1 多维数组的高效性能

（1）虽然可以使用[]运算符重复对嵌套列表进行索引，但多维数组支持更为自然的索引语法，只需一个[ ]和一组以逗号分隔的索引即可。比如返回第一行第二列的数值，如下所示。

```
print(LIST2[0][1])
print(ARR2[0,1])
#输出结果均为 2
```

比如返回 2 行 3 列的 array，且值全部为 0，如下所示。

```
np.zeros((2,3))
#输出结果为：array([[ 0.,  0.,  0.],
#                   [ 0.,  0.,  0.]])
```

再比如返回 2 行 4 列的 array，且值为均值为 10，标准差为 3 的正态分布的随机数，代码如下。

```
np.random.normal(10, 3, (2, 4))
#输出结果为：array([[ 11.29907857,  13.60911212,   7.10480299,  13.08482223],
#                   [ 10.68589039,  11.33541284,   6.59019336,  10.40541064]])
```

（2）实际上，只要元素的总数不变，数组的形状就可以随时改变。例如想要一个数字从 0 增加的 2×4 数组，最简单的方法如下所示。

```
arr1 = np.arange(8)
#输出结果为：array([0, 1, 2, 3, 4, 5, 6, 7])
arr2= np.arange(8).reshape(2, 4)
#输出结果为：array([[0, 1, 2, 3],
#                   [4, 5, 6, 7]])
```

注意：NumPy 数组形状的改变，就像 Numpy 中的大多数操作一样，改变前后存在相同的记忆。这种方式极大地提升了对向量的操作。

```
arr1 = np.arange(8)
arr2 = arr.reshape(2, 4)
arr1[0] = 1000
print(arr1)
print(arr2)
#输出结果为：[1000   1   2   3   4   5   6   7]
#          [[1000  1   2   3]
#          [       4   5   6   7]]
arr3=arr.copy()
arr1[0] = 1
print(arr3)
print(arr1)
print(arr2)
#输出结果为：[1 1 2 3 4 5 6 7]
#          [1 1 2 3 4 5 6 7]
#          [[1, 1, 2, 3],
#          [4, 5, 6, 7]])
```

8.3.2 多维数组的索引与切片

使用多维数组，仍然可以向一维数组一样使用切片，并且多维数组可以在不同维度中混合匹配切片和单个索引（本例将使用与 8.3.1 节相同的数组）。

```
print(arr2[1, 2:3])
print(arr2[:, 2])
print(arr2[1][2:3])
#输出结果为：
# [6]       返回第 2 行，第 3 列的值
# [2 6]     返回第三列的所有值
# [6]       返回第 2 行，第 3 列的值
LIST=[[1,2,3],[4,5,6]]
[i[2] for i in LIST]
#输出结果为：[3, 6]。
#如果只提供一个索引，那么将得到一个包含该行的维数少的数组，如下所示。
print(arr2[0])
print(arr2[1])
#输出结果
#[1 1 2 3]      返回第 1 行的所有值
#[4 5 6 7]      返回第 2 行的所有值
```

8.3.3 多维数组的属性

到这里，读者已经感受到了多维数组的高效与魅力，接下来深入了解数组最有用的属性和方法。首先了解有关数组大小、形状和数据的基本信息，如下所示。

```
arr = arr2
print('Data type                :', arr.dtype)
print('Total number of elements :', arr.size)
print('Number of dimensions     :', arr.ndim)
print('Shape (dimensionality)   :', arr.shape)
print('Memory used (in bytes)   :', arr.nbytes)
```

输出结果如下。

```
Data type                : int32
Total number of elements : 8
Number of dimensions     : 2
Shape (dimensionality)   : (2, 4)
Memory used (in bytes)   : 32
```

数组还有一些其他特别有用的方法，如下所示。

```
print('Minimum and maximum             :', arr.min(), arr.max())
print('Sum and product of all elements :', arr.sum(), arr.prod())
print('Mean and standard deviation     :', arr.mean(), arr.std())
```

输出结果如下。

```
Minimum and maximum            : 1 7
Sum and product of all elements: 29 5040
Mean and standard deviation    : 3.625 2.11763429326
```

上面所述的方法，其操作区域都是在数组的所有元素。对于多维数组，还可以通过传递轴参数，使数组沿着一个维度进行计算，如下所示。

```
print('The sum of elements along the rows is      :', arr.sum(axis=1))
print('The sum of elements along the columns is   :', arr.sum(axis=0))
arr.cumsum(axis=1)
```

输出结果如下。

```
[[1 1 2 3]
 [4 5 6 7]]
The sum of elements along the rows is      : [ 7 22]
The sum of elements along the columns is   : [ 5  6  8 10]
```

数组中另一个被广泛使用的属性是.T 属性，这个操作将会使得数组转置，如下所示。

```
print("Array: \n", arr)
print('Transpose: \n', arr.T)
```

输出结果如下。

```
Array:
 [[1 1 2 3]
```

```
 [4 5 6 7]]
Transpose:
 [[1 4]
 [1 5]
 [2 6]
 [3 7]]
```

其实数组的方法和属性有很多，在 NumPy 的文档中以及网络上都可以查到相应资料。这里不再一一列举，感兴趣的读者可自行探索学习。

8.4 数组的运算

NumPy 专为科学计算而生，本小节将介绍数组的运算。数组支持所有常规的算术运算，NumPy 库中包含完整的基本数学函数，这些函数在数组的运算上也发挥了很大的作用。一般来说，数组的所有操作都是以元素对应的方式实现的，即同时应用于数组的所有元素，且一一对应，如下所示。

```
arr1 = np.arange(4)
arr2 = np.arange(10, 14)
print(arr1, '+', arr2, '=', arr1+arr2)
```

输出结果如下。

```
[0 1 2 3] + [10 11 12 13] = [10 12 14 16]
```

值得注意的是，即使是乘法运算也是默认元素对应的方式，这与线性代数的矩阵乘法不同，如下所示。

```
print(arr1, '*', arr2, '=', arr1*arr2)
```

输出结果如下。

```
print(arr1, '*', arr2, '=', arr1*arr2)
#输出结果为：[0 1 2 3] * [10 11 12 13] = [ 0 11 24 39]，表示数组与数组相乘
print(1.5 * arr1)
#输出结果为：array([ 0. ,  1.5,  3. ,  4.5])，表示数组与数字相乘
```

NumPy 提供了完整的数学函数，并且可以在整个数组上运行，其中包括对数、指数、三角函数和双曲三角函数等。此外，SciPy 还在 scipy.special 模块中提供了一个丰富的特殊函数库，具有贝塞尔、艾里、菲涅耳等古典特殊功能。例如在 0 到 2π 之间的正弦函数上采集 20 个点，实现方式就像下面代码所展示的这样简单。

```
x = np.linspace(0, 2*np.pi, 20)
y = np.sin(x)
```

输出结果如下。

```
array([ 0.00000000e+00,   3.24699469e-01,   6.14212713e-01,
        8.37166478e-01,   9.69400266e-01,   9.96584493e-01,
        9.15773327e-01,   7.35723911e-01,   4.75947393e-01,
        1.64594590e-01,  -1.64594590e-01,  -4.75947393e-01,
       -7.35723911e-01,  -9.15773327e-01,  -9.96584493e-01,
       -9.69400266e-01,  -8.37166478e-01,  -6.14212713e-01,
       -3.24699469e-01,  -2.44929360e-16])
```

第 9 章

pandas 数据清洗

9.1 数据读写、选择、整理和描述

pandas 是用于数据清洗的库，安装 pandas 需要很多依赖的库，安装起来比较麻烦，建议读者使用 Anaconda，Anaconda 内置了有关数据清洗和算法的库。为了避免读者安装 pandas 失败，本章以 Anaconda 作为开发环境介绍 pandas，下面介绍 pandas 的安装方法。

在 PyCharm 中安装 pandas，需要先安装 NumPy 和 python-dateutil，最后安装 pandas，如图 9-1 所示。

安装好 Anaconda 后，可以通过开始菜单执行 Jupyter Notebook，也可以通过组合键【Win+R】调出运行窗口，输入“jupyter notebook”，单击“确定”按钮，如图 9-2 所示。

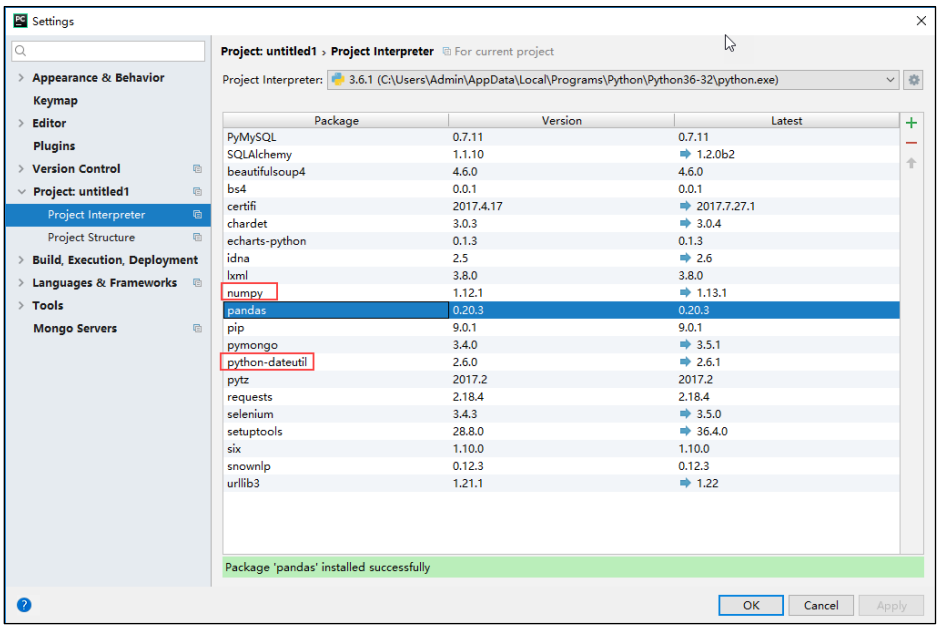

Package	Version	Latest
PyMySQL	0.7.11	0.7.11
SQLAlchemy	1.1.10	1.2.0b2
beautifulsoup4	4.6.0	4.6.0
bs4	0.0.1	0.0.1
certifi	2017.4.17	2017.7.27.1
chardet	3.0.3	3.0.4
echarts-python	0.1.3	0.1.3
idna	2.5	2.6
lxml	3.8.0	3.8.0
numpy	1.12.1	1.13.1
pandas	0.20.3	0.20.3
pip	9.0.1	9.0.1
pymongo	3.4.0	3.5.1
python-dateutil	2.6.0	2.6.1
pytz	2017.2	2017.2
requests	2.18.4	2.18.4
selenium	3.4.3	3.5.0
setuptools	28.8.0	36.4.0
six	1.10.0	1.10.0
snownlp	0.12.3	0.12.3
urllib3	1.21.1	1.22

图 9-1

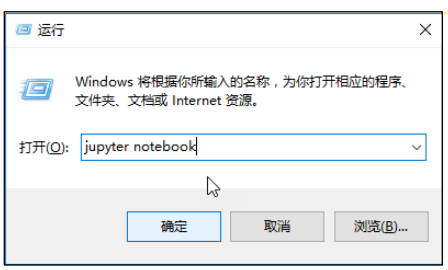

图 9-2

在默认浏览器中新建 jupyter 的页面，展开右侧的“New”下拉列表，并选择“Python 3”命令，从而新建 Python 3 的文件，如图 9-3 所示。

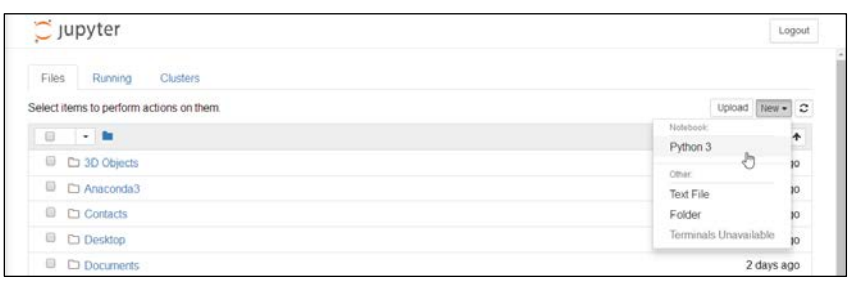

图 9-3

在新的选项卡中新建 Python 3 的文件后，脚本编辑环境如图 9-4 所示。

图 9-4

从“Hello，World!”开始，首先输入 print('Hello,World!')，然后单击运行按钮，如图 9-5 所示。

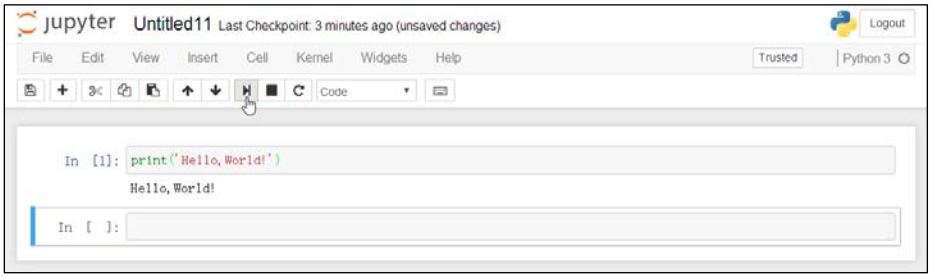

图 9-5

在 Anaconda 中，可以不使用 print 这类打印函数，Anaconda 会自动打印内容。

9.1.1　从 CSV 中读取数据

输入以下代码，用于读取数据。

```
import pandas as pd
# 从 CSV 中读取数据，还可以读取 html、txt 等格式的文件
df= pd.read_csv("D:/taobao_data.csv")
```

代码运行结果如图 9-6 所示。

	商品	价格	成交量	卖家	位置
0	新款中老年女装春装雪纺打底衫妈妈装夏装中袖宽松上衣中年人t恤	99.0	16647	夏亲凤凰旗舰店	江苏
1	中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装	286.0	14045	夏洛特的文艺	上海
2	母亲节衣服夏季妈妈装夏装套装短袖中年人40-50岁中老年女装T恤	298.0	13458	云新旗舰店	江苏
3	母亲节衣服中老年人春装女40岁50中年妈妈装套装夏装奶奶装两件套	279.0	13340	韶妃旗舰店	浙江
4	中老年女装春夏装裤大码 中年妇女40-50岁妈妈装夏装套装七分裤	59.0	12939	千百亲旗舰店	江苏

图 9-6

read_csv 还可以指定参数，使用方式如下。

```
df= pd.read_csv("D:/taobao_data.csv", delimiter=",", encoding="utf8", header=0)
```

说明

（1）根据所读取的数据文件编码格式设置 encoding 参数，如“utf8”、“ansi”和“gbk”等编码方式。

（2）根据所读取的数据文件列之间的分隔方式设置 delimiter 参数，大于一个字符的分隔符被看作正则表达式，如一个或多个空格（\s+）、tab 符号（\t）等。

9.1.2 向 CSV 写入数据

```
df.to_csv("D:/taobao_price_data.csv",columns=['商 品 ','价 格 '], index=False,header=True)
```

不要索引，只要列头、“商品”、“价格”三列。

说明

- index=False 将 DataFrame 保存成文件时，可以忽略索引信息。
- index=True 将 DataFrame 保存成文件时，需要同时保存索引信息（输出文件的第一列保存索引值）。

9.1.3 数据选择

1．行的选取

在 cell 中输入以下代码并执行。

```
rows = df[0:3]
rows
```

选择第 0 行至第 2 行，结果如图 9-7 所示。

	商品	价格	成交量	卖家	位置
0	新款中老年女装春装雪纺打底衫妈妈装夏装中袖宽松上衣中年人t恤	99.0	16647	夏亲凤凰旗舰店	江苏
1	中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装	286.0	14045	夏洛特的文艺	上海
2	母亲节衣服夏季妈妈装夏装套装短袖中年人40-50岁中老年女装T恤	298.0	13458	云新旗舰店	江苏

图 9-7

2．列的选取

输入以下代码并执行。

```
cols = df[['商品','价格']]
cols.head()
```

选择列头、“商品”和“价格”，结果如图 9-8 所示。

	商品	价格
0	新款中老年女装春装雪纺打底衫妈妈装夏装中袖宽松上衣中年人t恤	99.0
1	中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装	286.0
2	母亲节衣服夏季妈妈装夏装套装短袖中年人40-50岁中老年女装T恤	298.0
3	母亲节衣服中老年人春装女40岁50中年妈妈装套装夏装奶奶装两件套	279.0
4	中老年女装春夏装裤大码 中年妇女40-50岁妈妈装夏装套装七分裤	59.0

图 9-8

其中 head()用于显示数据框中前五行数据。

3．块的选取

输入以下代码并执行。

```
df.ix[0:3,['商品','价格']]
```

选择行和列组成的数据块，结果如图 9-9 所示。

	商品	价格
0	新款中老年女装春装雪纺打底衫妈妈装夏装中袖宽松上衣中年人t恤	99.0
1	中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装	286.0
2	母亲节衣服夏季妈妈装夏装套装短袖中年人40-50岁中老年女装T恤	298.0
3	母亲节衣服中老年人春装女40岁50中年妈妈装套装夏装奶奶装两件套	279.0

图 9-9

注意，此处的“0：3”相当于[0，1，2，3]。

4．操作行和块

从已有的列中创建一个新的列，代码如下。

```
df['销售额'] = df['价格'] * df['成交量']
df.head()
```

运行结果如图 9-10 所示。

	商品	价格	成交量	卖家	位置	销售额
0	新款中老年女装春装雪纺打底衫妈妈装夏装中袖宽松上衣中年人t恤	99.0	16647	夏亲凤凰旗舰店	江苏	1648053.0
1	中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装	286.0	14045	夏洛特的文艺	上海	4016870.0
2	母亲节衣服夏季妈妈装夏装套装短袖中年人40-50岁中老年女装T恤	298.0	13458	云新旗舰店	江苏	4010484.0
3	母亲节衣服中老年人春装女40岁50中年妈妈装套装夏装奶奶装两件套	279.0	13340	韶妃旗舰店	浙江	3721860.0
4	中老年女装春夏装裤大码 中年妇女40-50岁妈妈装夏装套装七分裤	59.0	12939	千百亲旗舰店	江苏	763401.0

图 9-10

5．根据条件过滤行

在方括号中加入判断条件来过滤行，条件必须返回 True 或者 False，代码如下。

```
df[(df['价格']<100) & (df['成交量']>10000) ]
```

代码运行结果如图 9-11 所示。

	商品	价格	成交量	卖家	位置	销售额
0	新款中老年女装春装雪纺打底衫妈妈装夏装中袖宽松上衣中年人t恤	99.0	16647	夏亲凤凰旗舰店	江苏	1648053.0
4	中老年女装春夏装裤大码 中年妇女40-50岁妈妈装夏装套装七分裤	59.0	12939	千百亲旗舰店	江苏	763401.0

图 9-11

9.1.4 数据整理

首先将数据框按照位置字段进行排序输入以下代码并执行。

```
df1 = df.set_index("位置") # set_index 将某个字段作为 index
df1 = df1.sort_index()
df1.head()
```

运行结果如图 9-12 所示。

	商品	价格	成交量	卖家
位置				
上海	中老年女装夏装套装加肥加大码T恤上衣妈妈装时尚短袖夏季两件套	298.0	5325	简港旗舰店
上海	中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装	286.0	14045	夏洛特的文艺
上海	中老年人女装套装妈妈装夏装大码奶奶装40-50岁60短袖T恤70两件套	29.0	4752	佳福妈妈商城
上海	母亲节衣服夏季中老年女装夏装套装上衣40-50岁妈妈装T恤衫两件套	198.0	7466	简港旗舰店
上海	母亲节中老年女装夏装短袖40-50岁雪纺衫大码妈妈装T恤宽上衣套装	49.0	4164	金良国际

图 9-12

然后将数据框按照“位置”和“卖家”两个字段进行排序，其中“位置”为第一个排序因子，代码如下。

```
    # sortlevel(0)表示根据第一个索引"位置"排序
    df2 = df.set_index(["位置", "卖家"]).sortlevel(0)
    df2.head()
```

代码运行结果如图 9-13 所示。

		商品	价格	成交量
位置	卖家			
上海	xudong158	中老年女装夏装短袖t恤衫中年妇女母亲节衣服妈妈装雪纺套装上衣	99.0	4572
	佳俪妈妈商城	中老年人女装套装妈妈装夏装大码奶奶装40-50岁60短袖T恤70两件套	29.0	4752
	夏洛特的文艺	中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装	286.0	14045
	妃莲蕊旗舰店	母亲节衣服妈妈装夏装套装40-50岁中年两件套中老年女装短袖雪纺	138.0	6037
	妃莲蕊旗舰店	母亲节衣服妈妈装夏装套装短袖中年人40-50岁中老年女装T恤两件套	128.0	4718

图 9-13

接下来将成交量按位置分组计算均值和求和。首先计算均值，代码如下。

```
    df_mean  =  df.drop(["商品","卖家"],  axis=1).groupby("位置").
mean().sort_values("成交量", ascending=False)
    df_sum  =  df.drop(["商品","卖家"],  axis=1).groupby("位置").
sum().sort_values("成交量", ascending=False)
    # drop (默认 axis=0) 是删掉行, axis=1 是删掉列
    # groupby 汇总
    # sort_values 排序
    df_mean
```

代码运行结果如图 9-14 所示。

如果将上述代码中的 df_mean 换成 df_sum，则代码运行结果如图 9-15 所示。

	价格	成交量
位置		
江苏	223.611364	7030.909091
上海	161.200000	6801.500000
湖北	254.714286	6182.000000
河北	152.000000	6050.666667
河南	119.000000	5986.000000
浙江	290.428571	5779.500000
广东	326.000000	5164.000000
北京	150.000000	4519.333333

图 9-14

	价格	成交量
位置		
江苏	9838.9	309360
浙江	8132.0	161826
上海	1612.0	68015
湖北	1783.0	43274
北京	900.0	27116
河北	456.0	18152
河南	119.0	5986
广东	326.0	5164

图 9-15

9.1.5　数据描述

为了快速了解数据的结构，需要掌握一些指令。

首先，查看表的数据信息，代码如下。

```
# 查看表的数据信息
df.info()
```

代码运行结果如图 9-16 所示。

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 100 entries, 0 to 99
Data columns (total 6 columns):
商品      100 non-null object
价格      100 non-null float64
成交量     100 non-null int64
卖家      100 non-null object
位置      100 non-null object
销售额     100 non-null float64
dtypes: float64(2), int64(1), object(3)
memory usage: 4.8+ KB
```

图 9-16

其次，查看表的描述性统计信息，代码如下。

```
# 查看表的描述性统计信息
df.describe()
```

代码运行结果如图 9-17 所示。

	价格	成交量	销售额
count	100.000000	100.00000	1.000000e+02
mean	231.669000	6388.93000	1.470502e+06
std	130.971061	2770.07536	9.767500e+05
min	29.000000	3956.00000	1.378080e+05
25%	128.750000	4476.50000	7.560158e+05
50%	198.000000	5314.50000	1.245078e+06
75%	298.000000	7053.75000	1.883465e+06
max	698.000000	16647.00000	4.213608e+06

图 9-17

9.2 数据分组、分割、合并和变形

9.2.1 数据分组

（1）将指定字段作为索引，汇总数据。

按“位置”进行分组，并计算“销量”列的平均值，可以访问“销量”列，并根据“位置”调用 groupby，代码如下。

```
grouped = df['成交量'].groupby(df['位置'])
grouped.mean()
```

代码运行结果如图 9-18 所示。

```
位置
上海    6801.500000
北京    4519.333333
广东    5164.000000
江苏    7030.909091
河北    6050.666667
河南    5986.000000
浙江    5779.500000
湖北    6182.000000
Name: 成交量, dtype: float64
```

图 9-18

如果一次传入多个数组，就会得到按多列数值分组的统计结果，代码如下。

```
means = df['成交量'].groupby([df['位置'], df['卖家']]).mean()
means
```

代码运行结果如图 9-19 所示。

```
位置  卖家
上海  xudong158            4572.000000
    佳福妈妈商城             4752.000000
    夏洛特的文艺            14045.000000
    妃莲慕旗舰店             5377.500000
    婆家娘家商城             5304.000000
    简港旗舰店              8141.000000
    金良国际               4164.000000
北京  bobolove987          4261.000000
    hi大脚丫               4460.000000
    taylor3699           4271.000000
    wonwon942            4415.000000
    凯飞服饰1717            5209.000000
    妈妈装工厂店1988          4500.000000
广东  安静式风格              5164.000000
江苏  ceo放牛              11655.000000
    kewang5188           5348.000000
    wuweihua0809         5641.000000
    zxtvszml            12087.000000
    云新旗舰店             13458.000000
    伊秋芙旗舰店             4382.000000
    依人怡慧no1            4163.000000
    依安雅旗舰店            12664.000000
    依诗曼妮               11125.000000
    便宜才是硬道理1234          4421.000000
    千百奈旗舰店            12939.000000
    名瑾旗舰店              5506.000000
    夏奈凤凰旗舰店           16647.000000
    夕牧旗舰店              10366.000000
```

图 9-19

此外，还可以将列名用作分组。

将“位置”作为索引，按均值汇总所有的数值指标，代码如下。

```
df.groupby('位置').mean()
```

代码运行结果如图 9-20 所示。

	价格	成交量	销售额
位置			
上海	161.200000	6801.500000	1.256211e+06
北京	150.000000	4519.333333	6.846817e+05
广东	326.000000	5164.000000	1.683464e+06
江苏	223.611364	7030.909091	1.551363e+06
河北	152.000000	6050.666667	9.224000e+05
河南	119.000000	5986.000000	7.123340e+05
浙江	290.428571	5779.500000	1.650173e+06
湖北	254.714286	6182.000000	1.536022e+06

图 9-20

将“位置”和“卖家”作为索引，按均值汇总所有数值指标，代码如下。

```
df.groupby(['位置', '卖家']).mean()
```

代码运行结果如图 9-21 所示。

		价格	成交量	销售额
位置	卖家			
上海	xudong158	99.000000	4572.000000	4.526280e+05
	佳福妈妈商城	29.000000	4752.000000	1.378080e+05
	夏洛特的文艺	286.000000	14045.000000	4.016870e+06
	妃莲慕旗舰店	133.000000	5377.500000	7.185050e+05
	婆家媳家商城	198.000000	5304.000000	1.050192e+06
	简港旗舰店	228.333333	8141.000000	1.754522e+06
	金良国际	49.000000	4164.000000	2.040360e+05
	bobolove987	98.000000	4261.000000	4.175780e+05
	hi大脚丫	138.000000	4460.000000	6.154800e+05

图 9-21

说明

- 在执行 df.groupby('位置').mean()时，结果中没有“卖家”列。这是因为 df['卖家']不是数值，所以从结果中排除了。在默认情况下，所有数值列都会被聚合。
- groupby 的 size 方法，它可以返回一个含有各分组大小的 Series，代码如下。

```
df.groupby(['位置', '卖家']).size()
```

代码运行结果如图 9-22 所示。

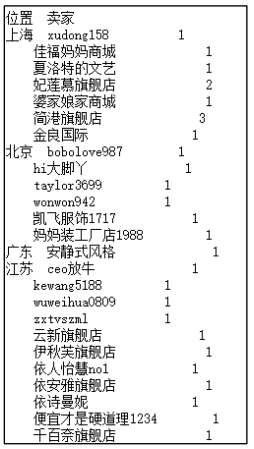

位置	卖家	
上海	xudong158	1
	佳福妈妈商城	1
	夏洛特的文艺	1
	妃莲慕旗舰店	2
	婆家娘家商城	1
	简港旗舰店	3
	金良国际	1
北京	bobolove987	1
	hi大脚丫	1
	taylor3699	1
	wonwon942	1
	凯飞服饰1717	1
	妈妈装工厂店1988	1
广东	安静式风格	1
江苏	ceo放牛	1
	kewang5188	1
	wuweihua0809	1
	zxtvszml	1
	云新旗舰店	1
	伊秋芙旗舰店	1
	依人怡慧no1	1
	依安雅旗舰店	1
	依诗曼妮	1
	便宜才是硬道理1234	1
	千百奈旗舰店	1

图 9-22

9.2.2　数据分割

进行数据分割的代码如下。

```
df1=df[30:40][['位置','卖家']]
#df1 中包含 df 的第 30~39 行数据，只保留“位置”，“卖家”两列
df2=df[80:90][['卖家','销售额']]
#df2 中包含 df 的第 80~89 行数据，只保留“卖家”，“销售额”两列
df1
```

代码运行结果如图 9-23 所示。

	位置	卖家
30	江苏	蒲洛妃旗舰店
31	江苏	悦薇孔雀旗舰店
32	江苏	摩尼树旗舰店
33	江苏	梵忆轩旗舰店
34	河北	loueddssd倍艾旗舰店
35	江苏	蒲洛妃旗舰店
36	上海	妃莲慕旗舰店
37	河南	z昊铭么么哒666
38	浙江	发财花旗舰店
39	浙江	香颜旗舰店

图 9-23

如果将上述代码中的 df1 换成 df2，则代码运行结果如图 9-24 所示。

	卖家	销售额
80	芭蒂卡旗舰店	829350.0
81	江苏妈妈装厂家直销	384120.0
82	香颜旗舰店	1363224.0
83	艾尔梦艺娜旗舰店	555861.0
84	金星靓雅服装店	495900.0
85	taylor3699	427100.0
86	bobolove987	417578.0
87	香颜旗舰店	1070748.0
88	金良国际	204036.0
89	依人怡慧no1	449604.0

图 9-24

9.2.3 数据合并

pandas 有一些内置的合并数据集方法，如下所示。

- pandas.merge 根据一个或多个键将多个 DataFrame 连接起来，类似数据库连接。
- pandas.concat 可以沿着一个轴将多个对象堆叠起来。
- combine_first 可以将重复数据编制在一起，用以填充另一个对象的缺失值。

1．数据库风格的 DataFrame 合并

数据库合并（merge）或连接（join）将一个或多个键将行连接起来，代码如下。

```
pd.merge(df1, df2)              #不指定列名，默认会选择列名相同的“卖家”列
pd.merge(df1, df2, on='卖家')   # 指定列名，结果同上
```

代码运行结果如图 9-25 所示。

	位置	卖家	销售额
0	浙江	香颜旗舰店	1363224.0
1	浙江	香颜旗舰店	1070748.0

图 9-25

这里，merge 方法默认使用 inner 连接（内连接），通过 how 参数可以指定连接方法。下面通过 how 参数将默认连接修改为 outer 连接（外连接），代码如下。

```
pd.merge(df1,df2,how='outer')
```

代码运行结果如图 9-26 所示。

	位置	卖家	销售额
0	江苏	蒲洛妃旗舰店	NaN
1	江苏	蒲洛妃旗舰店	NaN
2	江苏	悦薇孔雀旗舰店	NaN
3	江苏	摩尼树旗舰店	NaN
4	江苏	梵忆轩旗舰店	NaN
5	河北	loueddssd倍艾旗舰店	NaN
6	上海	妃莲慕旗舰店	NaN
7	河南	z昊铭么么哒666	NaN
8	浙江	发财花旗舰店	NaN
9	浙江	香颜旗舰店	1363224.0
10	浙江	香颜旗舰店	1070748.0
11	NaN	芭蒂卡旗舰店	829350.0
12	NaN	江苏妈妈装厂家直销	384120.0
13	NaN	艾尔梦艺娜旗舰店	555861.0
14	NaN	金星靓雅服装店	495900.0
15	NaN	taylor3699	427100.0
16	NaN	bobolove987	417578.0
17	NaN	金良国际	204036.0
18	NaN	依人怡慧no1	449604.0

图 9-26

通过 how 参数将默认连接修改为左连接，代码如下。

```
pd.merge(df1,df2,how='left')
```

代码运行结果如图 9-27 所示。

	位置	卖家	销售额
0	江苏	蒲洛妃旗舰店	NaN
1	江苏	悦薇孔雀旗舰店	NaN
2	江苏	摩尼树旗舰店	NaN
3	江苏	梵忆轩旗舰店	NaN
4	河北	loueddssd倍艾旗舰店	NaN
5	江苏	蒲洛妃旗舰店	NaN
6	上海	妃莲慕旗舰店	NaN
7	河南	z昊铭么么哒666	NaN
8	浙江	发财花旗舰店	NaN
9	浙江	香颜旗舰店	1363224.0
10	浙江	香颜旗舰店	1070748.0

图 9-27

通过 how 参数将默认连接修改为右连接，代码如下。

```
pd.merge(df1,df2,how='right',on='卖家')
```

代码运行结果如图 9-28 所示。

	位置	卖家	销售额
0	浙江	香颜旗舰店	1363224.0
1	浙江	香颜旗舰店	1070748.0
2	NaN	芭蒂卡旗舰店	829350.0
3	NaN	江苏妈妈装厂家直销	384120.0
4	NaN	艾尔梦艺娜旗舰店	555861.0
5	NaN	金星靓雅服装店	495900.0
6	NaN	taylor3699	427100.0
7	NaN	bobolove987	417578.0
8	NaN	金良国际	204036.0
9	NaN	依人怡慧no1	449604.0

图 9-28

2．索引上的合并

传入 left_index=True 或者 right_index=True，可以将索引作为连接键使用，代码如下。

```
df1=df[:10][['位置','卖家']]
df2=df[:10][['价格','成交量']]
df1
```

代码运行结果如图 9-29 所示。

	位置	卖家
0	江苏	夏亲凤凰旗舰店
1	上海	夏洛特的文艺
2	江苏	云新旗舰店
3	浙江	韶妃旗舰店
4	江苏	千百亲旗舰店
5	江苏	依安雅旗舰店
6	湖北	千百萌旗舰店
7	江苏	zxtvszml
8	江苏	ceo放牛
9	上海	简港旗舰店

图 9-29

如果将上述代码中的 df1 换成 df2，则代码运行结果如图 9-30 所示。

	价格	成交量
0	99.0	16647
1	286.0	14045
2	298.0	13458
3	279.0	13340
4	59.0	12939
5	198.0	12664
6	199.0	12398
7	288.0	12087
8	298.0	11655
9	189.0	11632

图 9-30

将 DataFrame 的 index 作为连接键，代码如下。

```
pd.merge(df1, df2, left_index=True, right_index=True)
```

代码运行结果如图 9-31 所示。

	位置	卖家	价格	成交量
0	江苏	夏奈凤凰旗舰店	99.0	16647
1	上海	夏洛特的文艺	286.0	14045
2	江苏	云新旗舰店	298.0	13458
3	浙江	韶妃旗舰店	279.0	13340
4	江苏	千百奈旗舰店	59.0	12939
5	江苏	依安雅旗舰店	198.0	12664
6	湖北	千百萌旗舰店	199.0	12398
7	江苏	zxtvszml	288.0	12087
8	江苏	ceo放牛	298.0	11655
9	上海	简港旗舰店	189.0	11632

图 9-31

DataFrame 还有 join 方法，可以更好地合并索引，代码如下。

```
df1.join(df2)
#效果同 pd.merge(df1, df2, left_index=True, right_index=True)
```

代码运行结果如图 9-32 所示。

	位置	卖家	价格	成交量
0	江苏	夏亲凤凰旗舰店	99.0	16647
1	上海	夏洛特的文艺	286.0	14045
2	江苏	云新旗舰店	298.0	13458
3	浙江	韶妃旗舰店	279.0	13340
4	江苏	千百亲旗舰店	59.0	12939
5	江苏	依安雅旗舰店	198.0	12664
6	湖北	千百萌旗舰店	199.0	12398
7	江苏	zxtvszml	288.0	12087
8	江苏	ceo放牛	298.0	11655
9	上海	简港旗舰店	189.0	11632

图 9-32

3．轴向连接

这是另一种连接，也被称为连接、绑定或堆叠，代码如下。

```
s1=df[:5]['商品']
s2=df[5:10]['商品']
s3=df[10:15]['商品']
pd.concat([s1,s2,s3])
```

代码运行结果如图 9-33 所示。

```
0          新款中老年女装春装雪纺打底衫妈妈装夏装中袖宽松上衣中年人t恤
1          中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装
2        母亲节衣服夏季妈妈装夏装套装短袖中年人40-50岁中老年女装T恤
3        母亲节衣服中老年人春装女40岁50中年妈妈装套装夏装奶奶装两件套
4        中老年女装春夏装裤大码  中年妇女40-50岁妈妈装夏装套装七分裤
5      中老年女装夏装短袖T恤40-50岁中年春装30打底衫妈妈装母亲节衣服
6       妈妈装春夏装T恤宽松雪纺衬衫40-50岁中老年女装大码中袖上衣套装
7       中老年女装夏季T恤雪纺衫妈妈装夏装套装短袖中年妇女40-50岁t恤
8       妈妈夏装两件套母亲节衣服老人上衣60-70岁人夏季中老年女装套装
9          中老年女装夏装套装圆领上衣裤子夏季中年妈妈装短袖T恤两件套
10       母亲节衣服夏季中年女装春装套装40-50岁妈妈装外套中老年人上衣
11        母亲节衣服中老年人女装奶奶短袖两件套中年40岁胖妈妈装夏装套装
12       母亲节中老年女装短袖t恤40-50岁中年妈妈装夏装套装上衣两件套
13        母亲节中老年女装短袖t恤40-50岁中年妈妈装夏装雪纺两件套装
14         中老年女装春装真两件套长袖针织开衫外套妈妈装夏装短袖T恤上衣
Name: 商品, dtype: object
```

图 9-33

输入以下代码。

```
s1=df[:5]['商品']
s2=df[:5]['价格']
s3=df[:5]['成交量']
pd.concat([s1,s2,s3],axis=1) # 做一个 DataFrame 出来
```

代码运行结果如图 9-34 所示。

	商品	价格	成交量
0	新款中老年女装春装雪纺打底衫妈妈装夏装中袖宽松上衣中年人t恤	99.0	16647
1	中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装	286.0	14045
2	母亲节衣服夏季妈妈装夏装套装短袖中年人40-50岁中老年女装T恤	298.0	13458
3	母亲节衣服中老年人春装女40岁50中年妈妈装套装夏装奶奶装两件套	279.0	13340
4	中老年女装春夏装裤大码 中年妇女40-50岁妈妈装夏装套装七分裤	59.0	12939

图 9-34

同样的逻辑，对 DataFrame 也是一样的，代码如下。

```
df1=df[:5][['位置','卖家']]
df2=df[:5][['价格','成交量']]
pd.concat([df1,df2])
```

代码运行结果如图 9-35 所示。

	价格	位置	卖家	成交量
0	NaN	江苏	夏亲凤凰旗舰店	NaN
1	NaN	上海	夏洛特的文艺	NaN
2	NaN	江苏	云新旗舰店	NaN
3	NaN	浙江	韶妃旗舰店	NaN
4	NaN	江苏	千百亲旗舰店	NaN
0	99.0	NaN	NaN	16647.0
1	286.0	NaN	NaN	14045.0
2	298.0	NaN	NaN	13458.0
3	279.0	NaN	NaN	13340.0
4	59.0	NaN	NaN	12939.0

图 9-35

然后输入以下代码。

```
pd.concat([df1,df2],axis=1)
```

则代码运行结果如图 9-36 所示。

	位置	卖家	价格	成交量
0	江苏	夏亲凤凰旗舰店	99.0	16647
1	上海	夏洛特的文艺	286.0	14045
2	江苏	云新旗舰店	298.0	13458
3	浙江	韶妃旗舰店	279.0	13340
4	江苏	千百亲旗舰店	59.0	12939

图 9-36

9.2.4 数据变形

1. 重塑层次化索引

针对 DataFrame，有 stack()函数和 unstack()函数。stack()将数据的列“旋转”为行，unstack()反之。

首先输入以下代码。

```
data= pd.read_csv("D:/hz_weather.csv")
data.head()
```

代码运行结果如图 9-37 所示。

	日期	最高气温	最低气温	天气	风向	风力
0	2017-01-01	17	7	晴	西北风	2级
1	2017-01-02	16	8	多云	东北风	2级
2	2017-01-03	15	8	多云	东北风	1级
3	2017-01-04	15	11	小雨	西北风	2级
4	2017-01-05	13	11	小到中雨	北风	2级

图 9-37

接下来输入以下代码。

```
data.stack()  # 把列转化为行，即形成一个层次化索引的 Series
```

代码运行结果如图 9-38 所示。

```
0  日期        2017-01-01
   最高气温          17
   最低气温           7
   天气              晴
   风向           西北风
   风力            2级
1  日期        2017-01-02
   最高气温          16
   最低气温           8
   天气             多云
   风向           东北风
   风力            2级
2  日期        2017-01-03
   最高气温          15
   最低气温           8
   天气             多云
   风向           东北风
   风力            1级
3  日期        2017-01-04
   最高气温          15
   最低气温          11
   天气             小雨
   风向           西北风
   风力            2级
4  日期        2017-01-05
   最高气温          13
   最低气温          11
   天气           小到中雨
   风向            北风
   风力            2级
```

图 9-38

然后输入以下代码。

```
data.stack().unstack()  # 把层次化索引的 Series 转化为一个普通的 DataFrame
```

代码运行结果如图 9-39 所示。

	日期	最高气温	最低气温	天气	风向	风力
0	2017-01-01	17	7	晴	西北风	2级
1	2017-01-02	16	8	多云	东北风	2级
2	2017-01-03	15	8	多云	东北风	1级
3	2017-01-04	15	11	小雨	西北风	2级
4	2017-01-05	13	11	小到中雨	北风	2级
5	2017-01-06	12	10	小雨	东北风	1级
6	2017-01-07	11	9	中雨	北风	2级
7	2017-01-08	12	5	多云	北风	2级
8	2017-01-09	11	4	多云	东北风	2级
9	2017-01-10	9	4	多云	北风	1级
10	2017-01-11	8	5	小雨	北风	1级

图 9-39

2．数据透视表

首先输入以下代码。

```
df=data.set_index('日期')
df
```

代码运行结果如图 9-40 所示。

	最高气温	最低气温	天气	风向	风力
日期					
2017-01-01	17	7	晴	西北风	2级
2017-01-02	16	8	多云	东北风	2级
2017-01-03	15	8	多云	东北风	1级
2017-01-04	15	11	小雨	西北风	2级
2017-01-05	13	11	小到中雨	北风	2级

图 9-40

df 表中以“最高气温”作为数值域，“天气”为行，“风向”为列的数据视图，代码如下。

```
df1=pd.pivot_table(df, values=['最高气温'], index=['天气'], columns=['风向'])
df1
```

代码运行结果如图 9-41 所示。

	最高气温						
风向	东北风	东南风	东风	北风	南风	西北风	西南风
天气							
中雨	11.000000	NaN	18.5	11.000000	NaN	NaN	NaN
多云	14.111111	13.75	15.0	13.333333	24.333333	21.0	18.666667
小到中雨	NaN	NaN	NaN	13.000000	NaN	NaN	NaN
小雨	13.500000	11.00	14.5	9.250000	NaN	14.0	13.000000
晴	10.250000	15.80	18.0	18.000000	19.000000	18.0	27.500000
阴	13.500000	16.00	13.0	15.600000	14.000000	11.0	NaN
阵雨	NaN	21.00	26.0	15.333333	28.000000	12.0	27.500000
雨夹雪	NaN	NaN	NaN	7.000000	NaN	NaN	NaN

图 9-41

然后输入以下代码。

```
df1.info()
```

代码运行结果如图 9-42 所示。

```
<class 'pandas.core.frame.DataFrame'>
Index: 8 entries, 中雨 to 雨夹雪
Data columns (total 7 columns):
(最高气温, 东北风)    5 non-null float64
(最高气温, 东南风)    5 non-null float64
(最高气温, 东风)      6 non-null float64
(最高气温, 北风)      8 non-null float64
(最高气温, 南风)      4 non-null float64
(最高气温, 西北风)    5 non-null float64
(最高气温, 西南风)    4 non-null float64
dtypes: float64(7)
memory usage: 512.0+ bytes
```

图 9-42

9.2.5 案例：旅游数据的分析与变形

接下来展示某旅游网站自由行路线数据的分组、分割、合并与变形，具体步骤如下。

首先输入以下代码。

```
# 读取自由行路线数据表
import pandas as pd
df = pd.read_csv("D:/qunar_free_trip.csv")
df.head()
```

代码运行结果如图 9-43 所示。

	出发地	目的地	价格	节省	路线名	酒店	房间	去程航司	去程方式	去程时间	回程航司	回程方式	回程时间
0	北京	厦门	1866	492	北京-厦门3天2晚 | 入住厦门温特雅酒店 + 联合航空/首都航空往返机票	厦门温特雅酒店 舒适型 3.9分/5分	标准房(大床)(预付) 大床 不含早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15
1	北京	厦门	2030	492	北京-厦门3天2晚 | 入住厦门华美达长升大酒店 + 联合航空/首都航空往返机票	厦门华美达长升大酒店 4.1分/5分	标准房(错峰出游) 大/双床 双早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15
2	北京	厦门	2139	533	北京-厦门3天2晚 | 入住厦门毕思特酒店 + 联合航空/首都航空往返机票	厦门毕思特酒店 高档型 4.4分/5分	标准大床房(特惠)[双... 大床 双早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15
3	北京	厦门	2141	502	北京-厦门3天2晚 | 入住厦门翔鹭国际大酒店 + 联合航空/首都航空往返机票	厦门翔鹭国际大酒店 豪华型 4.4分/5分	高级大床房(含单早) 其他 单早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15
4	北京	厦门	2159	524	北京-厦门3天2晚 | 入住厦门京闽中心酒店 + 联合航空/首都航空往返机票	厦门京闽中心酒店 4.5分/5分	高级房(双床)(新春特... 双床 双早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15

图 9-43

然后输入以下代码。

```
# 按出发地、目的地分组查看价格均值
df["价格"].groupby([df["出发地"],df["目的地"]]).mean()
```

代码运行结果如图 9-44 所示。

```
出发地  目的地
上海    三亚       1627.350000
        丽江       1981.490000
        乌鲁木齐    3223.760000
        九寨沟     1893.712500
        北京       1317.090000
        厦门       1322.670000
        呼和浩特    1561.230000
        哈尔滨     1352.990000
        大连       1258.300000
        太原       1412.790000
        张家界     2203.230000
        桂林       1325.830000
        武汉       1136.220000
        沈阳       1455.610000
        神农架     1264.580000
        西双版纳    3693.310000
        西安       1381.830000
        重庆       1641.170000
        长沙       1147.920000
        青岛        886.320000
        黄山       1290.330000
北京    三亚       2760.400000
        丽江       1958.160000
        乌鲁木齐    2362.060000
        九寨沟     1953.740000
        厦门       1902.380000
        哈尔滨     1437.990000
        大理       3475.980000
        大连       1218.300000
        张家界     2249.930000
```

图 9-44

接下来输入以下代码。

```
# 读取路线总数
df_ = pd.read_csv("D:/qunar_route_cnt.csv")
df_.head()
```

代码运行结果如图 9-45 所示。

	出发地	目的地	路线页数
0	北京	厦门	359
1	北京	青岛	471
2	北京	杭州	1228
3	北京	丽江	1160
4	北京	九寨沟	168

图 9-45

接下来输入以下代码。

```
# 按出发地、目的地分组生成价格均值汇总表
df1 = df.groupby([df["出发地"],df["目的地"]], as_index=False).mean()
df1
```

代码运行结果如图 9-46 所示。

	出发地	目的地	价格	节省
0	上海	三亚	1627.350000	444.390000
1	上海	丽江	1981.490000	569.380000
2	上海	乌鲁木齐	3223.760000	711.800000
3	上海	九寨沟	1893.712500	492.425000
4	上海	北京	1317.090000	344.650000
5	上海	厦门	1322.670000	339.510000
6	上海	呼和浩特	1561.230000	432.320000
7	上海	哈尔滨	1352.990000	357.960000
8	上海	大连	1258.300000	351.340000
9	上海	太原	1412.790000	433.600000
10	上海	张家界	2203.230000	539.200000
11	上海	桂林	1325.830000	351.800000
12	上海	武汉	1136.220000	335.930000
13	上海	沈阳	1455.610000	387.260000
14	上海	神农架	1264.580000	352.280000

图 9-46

接下来输入以下代码。

```
# 将价格均值汇总表和路线总数表合并
```

```
pd.merge(df1,df_).head(10)
```

代码运行结果如图 9-47 所示。

	出发地	目的地	价格	节省	路线页数
0	上海	三亚	1627.3500	444.390	397
1	上海	丽江	1981.4900	569.380	1159
2	上海	乌鲁木齐	3223.7600	711.800	136
3	上海	九寨沟	1893.7125	492.425	168
4	上海	北京	1317.0900	344.650	1444
5	上海	厦门	1322.6700	339.510	357
6	上海	呼和浩特	1561.2300	432.320	125
7	上海	哈尔滨	1352.9900	357.960	285
8	上海	大连	1258.3000	351.340	242
9	上海	太原	1412.7900	433.600	212

图 9-47

接下来输入以下代码。

```
# 查看出发地 vs 目的地 vs 平均价格的数据透视表
df2 = pd.pivot_table(df,values=["价格"],index=["出发地"],columns=["目的地
"])
df2.head(8)
```

代码运行结果如图 9-48 所示。

	价格										...						
目的地	三亚	三亚湾	上海	丽江	乌鲁木齐	九寨沟	兰州	北京	北海	南京	...	西安	鄂尔多斯	重庆	银川	长春	长沙
出发地																	
上海	1627.35	NaN	NaN	1981.49	3223.76	1893.7125	NaN	1317.09	NaN	NaN	...	1381.83	NaN	1641.17	NaN	NaN	1147.9200
北京	2760.40	NaN	NaN	1958.16	2362.06	1953.7400	NaN	NaN	NaN	NaN	...	1283.86	NaN	NaN	1025.14	NaN	1300.9200
南京	1886.40	NaN	NaN	1775.49	NaN	1963.3500	NaN	NaN	1856.77	NaN	...	966.83	NaN	1185.18	NaN	NaN	988.01000
厦门	1464.84	NaN	NaN	NaN	3018.21	2079.4800	NaN	1390.80	NaN	NaN	...	1475.25	NaN	1462.29	NaN	NaN	1143.1666
哈尔滨	2102.84	NaN	NaN	NaN	NaN	1866.5300	NaN	NaN	2318.29	1164.69697	...	1961.25	NaN	NaN	NaN	NaN	1831.0000
大连	2955.01	NaN	1191.41	NaN	NaN	2115.2000	NaN	NaN	NaN	NaN	...	1104.94	NaN	1742.29	NaN	NaN	1680.0100
天津	2085.35	NaN	NaN	1654.49	NaN	1994.7000	NaN	NaN	2085.30	NaN	...	984.89	NaN	1464.17	NaN	NaN	1183.9200
宁波	NaN	NaN	NaN	NaN	NaN	2067.2000	2552.84	NaN	NaN	NaN	...	1736.94	NaN	1686.29	NaN	NaN	1124.0100

图 9-48

最后输入以下代码。

```
# 从杭州出发的目的地 vs 去程方式 vs 平均价格的数据透视表
```

```
    df1 = pd.pivot_table(df[df["出发地"]=="杭州"],values=["价格"],index=["出发地","目的地"],columns=["去程方式"])
    df1
```

代码运行结果如图 9-49 所示。

		价格	
	去程方式	直飞	经停
出发地	目的地		
杭州	三亚	1839.35	NaN
	丽江	NaN	2918.320000
	九寨沟	NaN	1952.700000
	北海	NaN	2910.000000
	厦门	1208.38	NaN
	呼和浩特	NaN	1557.570000
	哈尔滨	NaN	1690.990000
	大连	1710.09	NaN
	天子山	1682.03	NaN
	天津	1506.03	NaN
	张家界	1682.03	NaN
	成都	NaN	1898.811111
	桂林	1438.98	NaN
	武汉	1190.16	NaN
	沈阳	1948.03	NaN
	西双版纳	NaN	1716.310000
	西宁	NaN	2851.820000
	西安	1242.89	NaN
	重庆	1644.17	NaN
	长沙	1160.92	NaN
	青岛	1049.23	NaN

图 9-49

9.3 缺失值、异常值和重复值处理

9.3.1 缺失值处理

当数据中存在 NaN 缺失值时，可以用其他数值替代缺失值。这里主要用到了 DataFrame.fillna() 方法，具体的用法如下。

1．查看是否有缺失值

输入以下代码。

```
    df= pd.read_csv("D:/hz_weather.csv")
    df1=pd.pivot_table(df, values=['最高气温'], index=['天气'], columns=['风向'])
```

```
df1.isnull()
```

代码运行结果如图 9-50 所示。

	最高气温						
风向	东北风	东南风	东风	北风	南风	西北风	西南风
天气							
中雨	False	True	False	False	True	True	True
多云	False	False	False	False	False	False	False
小到中雨	True	True	True	False	True	True	True
小雨	False	False	False	False	True	False	False
晴	False	False	False	False	False	False	False
阴	False	False	False	False	False	False	True
阵雨	True	False	False	False	False	False	False
雨夹雪	True	True	True	False	True	True	True

图 9-50

2．使用参数 axis=0，选择删除行

这种方法较为常用，代码如下。

```
df1.dropna(axis=0)
```

代码运行结果如图 9-51 所示。

	最高气温						
风向	东北风	东南风	东风	北风	南风	西北风	西南风
天气							
多云	14.111111	13.75	15.0	13.333333	24.333333	21.0	18.666667
晴	10.250000	15.80	18.0	18.000000	19.000000	18.0	27.500000

图 9-51

3．选择删除列

这种情况不多见，因为通常我们选择用列来表示一个变量或者指标，通常不会因为有几个缺失值就删除一个变量。使用这种方法时，代码如下。

```
df1.dropna(axis=1)
```

代码运行结果如图 9-52 所示。

	最高气温
风向	北风
天气	
中雨	11.000000
多云	13.333333
小到中雨	13.000000
小雨	9.250000
晴	18.000000
阴	15.600000
阵雨	15.333333
雨夹雪	7.000000

图 9-52

4．使用字符串代替缺失值

使用这种方法时，代码如下。

```
df1.fillna('missing')
```

代码运行结果如图 9-53 所示。

	最高气温						
风向	东北风	东南风	东风	北风	南风	西北风	西南风
天气							
中雨	11	missing	18.5	11.000000	missing	missing	missing
多云	14.1111	13.75	15	13.333333	24.3333	21	18.6667
小到中雨	missing	missing	missing	13.000000	missing	missing	missing
小雨	13.5	11	14.5	9.250000	missing	14	13
晴	10.25	15.8	18	18.000000	19	18	27.5
阴	13.5	16	13	15.600000	14	11	missing
阵雨	missing	21	26	15.333333	28	12	27.5
雨夹雪	missing	missing	missing	7.000000	missing	missing	missing

图 9-53

5．使用前一个数据代替 NaN：method='pad'

使用这种方法时，代码如下。

```
df1.fillna(method='pad')
```

代码运行结果如图 9-54 所示。

	最高气温						
风向	东北风	东南风	东风	北风	南风	西北风	西南风
天气							
中雨	11.000000	NaN	18.5	11.000000	NaN	NaN	NaN
多云	14.111111	13.75	15.0	13.333333	24.333333	21.0	18.666667
小到中雨	14.111111	13.75	15.0	13.000000	24.333333	21.0	18.666667
小雨	13.500000	11.00	14.5	9.250000	24.333333	14.0	13.000000
晴	10.250000	15.80	18.0	18.000000	19.000000	18.0	27.500000
阴	13.500000	16.00	13.0	15.600000	14.000000	11.0	27.500000
阵雨	13.500000	21.00	26.0	15.333333	28.000000	12.0	27.500000
雨夹雪	13.500000	21.00	26.0	7.000000	28.000000	12.0	27.500000

图 9-54

6．bfill 表示用后一个数据代替 NaN

用 limit 限制每列可以替代 NaN 的数目，下面限制每列只能替代一个 NaN，代码如下。

```
df1.fillna(method='bfill',limit=1)
```

代码运行结果如图 9-55 所示。

	最高气温						
风向	东北风	东南风	东风	北风	南风	西北风	西南风
天气							
中雨	11.000000	13.75	18.5	11.000000	24.333333	21.0	18.666667
多云	14.111111	13.75	15.0	13.333333	24.333333	21.0	18.666667
小到中雨	13.500000	11.00	14.5	13.000000	NaN	14.0	13.000000
小雨	13.500000	11.00	14.5	9.250000	19.000000	14.0	13.000000
晴	10.250000	15.80	18.0	18.000000	19.000000	18.0	27.500000
阴	13.500000	16.00	13.0	15.600000	14.000000	11.0	27.500000
阵雨	NaN	21.00	26.0	15.333333	28.000000	12.0	27.500000
雨夹雪	NaN	NaN	NaN	7.000000	NaN	NaN	NaN

图 9-55

使用平均数或者其他描述性统计量来代替 NaN 使用这种方法时，代码如下。

```
df1.fillna(df1.mean())
```

代码运行结果如图 9-56 所示。

	最高气温						
风向	东北风	东南风	东风	北风	南风	西北风	西南风
天气							
中雨	11.000000	15.51	18.5	11.000000	21.333333	15.2	21.666667
多云	14.111111	13.75	15.0	13.333333	24.333333	21.0	18.666667
小到中雨	12.472222	15.51	17.5	13.000000	21.333333	15.2	21.666667
小雨	13.500000	11.00	14.5	9.250000	21.333333	14.0	13.000000
晴	10.250000	15.80	18.0	18.000000	19.000000	18.0	27.500000
阴	13.500000	16.00	13.0	15.600000	14.000000	11.0	21.666667
阵雨	12.472222	21.00	26.0	15.333333	28.000000	12.0	27.500000
雨夹雪	12.472222	15.51	17.5	7.000000	21.333333	15.2	21.666667

图 9-56

9.3.2 检测和过滤异常值

发现异常值和极端值的方法是对数据进行描述性统计，而使用 describe 函数则可以生成描述统计结果。

1．基于统计与数据分布

假设数据集应满足正态分布（Normal Distribution），即：

$$P(\alpha;\mu,\sigma)=\frac{1}{\sqrt{2\pi\sigma^2}}\exp\left(-\frac{(\alpha-\mu)^2}{2\sigma_2}\right),\qquad \alpha\in[-\infty;\infty]$$

这里，分布的平均值为 μ，方差为 σ^2。

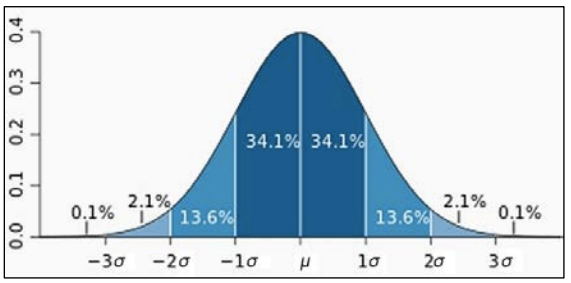

图 9-57

如果 x 的值大于 3 σ 或者小于-3 σ，那么都可以认为是异常值（参见图 9-57），代码如下。

```
%matplotlib inline
import matplotlib as mpl
import matplotlib.pyplot as plt
df=pd.read_csv("D:/hz_weather.csv")
```

```
fig, ax = plt.subplots(1, 1, figsize=(8, 5))
ax.hist(df["最低气温"],bins=20)
d = df["最低气温"]
zscore = (d - d.mean())/d.std()
df['isOutlier'] = zscore.abs() > 3
df['isOutlier'].value_counts()
```

代码运行结果如图 9-58 所示。

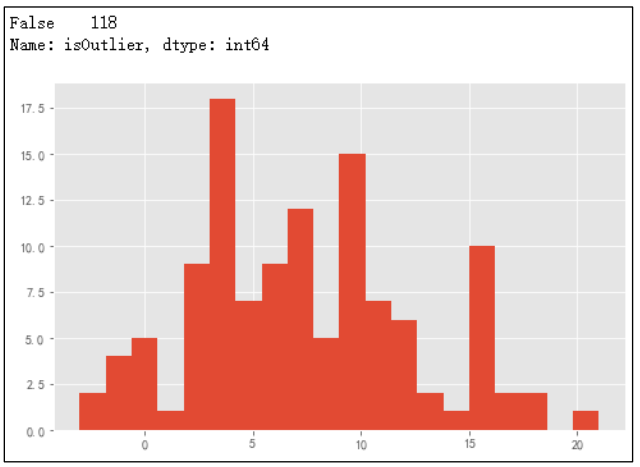

图 9-58

2．箱形图分析

箱形图可以用来观察数据整体的分布情况，利用中位数、25%分位数，75%分位数、上边界和下边界等统计量来描述数据的整体分布情况。通过计算这些统计量，生成一个箱形图，箱体中的数据一般被认为是正常的，而在箱体上边界和下边界之外的数据，通常被认为是异常的。

```
%matplotlib inline
import matplotlib as mpl
import matplotlib.pyplot as plt
df=pd.read_csv("D:/sale_data.csv")
fig, ax = plt.subplots(1, 1, figsize=(8, 5))
df_=df[df["子行业名称"]=="羽绒服"]
df_.boxplot(column="成交量",ax=ax)
d=df_["成交量"]
print (d.describe())
df_['isOutlier'] = d > d.quantile(0.75)
df_[df_['isOutlier']==True]
```

代码运行效果如图 9-59、图 9-60 和图 9-61 所示。

```
count     2.500000e+01
mean      9.818319e+05
std       1.502757e+06
min       1.746800e+04
25%       7.623500e+04
50%       2.427510e+05
75%       1.056998e+06
max       5.289075e+06
Name: 成交量, dtype: float64
```

图 9-59

	子行业名称	成交量	销售额	高质商品数	年	月	isOutlier
2	羽绒服	1343759	766819840	73181	2012	1	True
255	羽绒服	3862246	2541386685	101261	2012	11	True
277	羽绒服	5289075	3924740522	110398	2012	12	True
302	羽绒服	4262219	3330737056	121260	2013	1	True
584	羽绒服	1717377	913287190	58773	2011	11	True
602	羽绒服	3130067	1764737225	104287	2011	12	True

图 9-60

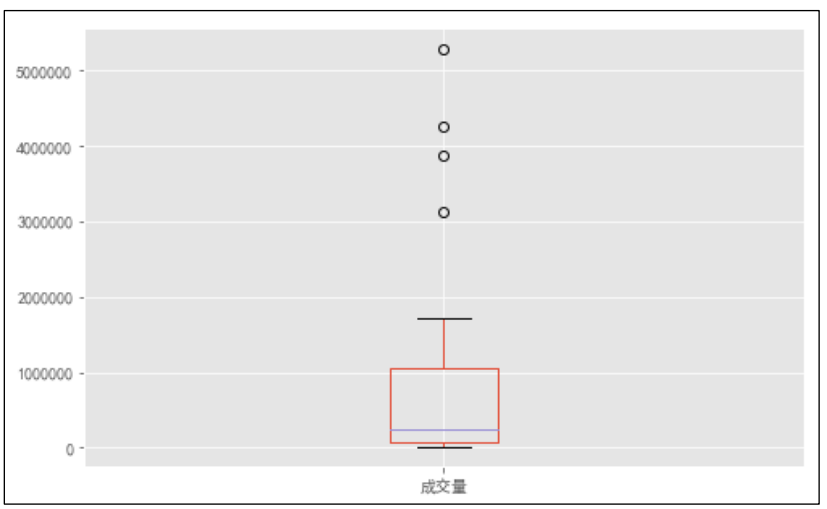

图 9-61

9.3.3　移除重复数据

其中 duplicated 方法返回一个 bool 型 Series，用以判断某行是否为重复行；drop_duplicates 方法返回一个删除了重复行的 DataFrame，具体操作如下。

首先输入以下代码。

```
df=pd.read_CSV("D:/hz_weather.CSV")
df.duplicated()
```

代码运行结果如图 9-62 所示。

```
日期
2017-01-01    False
2017-01-02    False
2017-01-03    False
2017-01-04    False
2017-01-05    False
2017-01-06    False
2017-01-07    False
2017-01-08    False
2017-01-09    False
2017-01-10    False
2017-01-11    False
2017-01-12    False
2017-01-13    False
2017-01-14    False
2017-01-15    False
2017-01-16    False
2017-01-17    False
2017-01-18    False
2017-01-19    False
2017-01-20    False
2017-01-21    False
2017-01-22    False
2017-01-23    False
2017-01-24    False
2017-01-25     True
2017-01-26    False
2017-01-27    False
2017-01-28     True
2017-01-29    False
2017-01-30     True
              ...
```

图 9-62

然后输入以下代码。

```
data.duplicated('最高气温')  # 按照列进行判断
```

代码运行结果如图 9-63 所示。

日期	
2017-01-01	False
2017-01-02	False
2017-01-03	False
2017-01-04	True
2017-01-05	False
2017-01-06	False
2017-01-07	False
2017-01-08	True
2017-01-09	True
2017-01-10	False
2017-01-11	False
2017-01-12	False
2017-01-13	False
2017-01-14	True
2017-01-15	True
2017-01-16	True
2017-01-17	True
2017-01-18	True
2017-01-19	True
2017-01-20	False
2017-01-21	True
2017-01-22	True
2017-01-23	True
2017-01-24	True
2017-01-25	True
2017-01-26	True
2017-01-27	True
2017-01-28	True
2017-01-29	False
2017-01-30	True
	...

图 9-63

最后输入以下代码。

```
df.drop_duplicates('最高气温')  # 返回一个新的去重后的对象
```

代码运行结果如图 9-64 所示。

	最高气温	最低气温
日期		
2017-01-01	17	7
2017-01-02	16	8
2017-01-03	15	8
2017-01-05	13	11
2017-01-06	12	10
2017-01-07	11	9
2017-01-10	9	4
2017-01-11	8	5
2017-01-12	7	4
2017-01-13	10	1
2017-01-20	6	-3

图 9-64

9.3.4　案例：旅游数据的值检查与处理

这里进行某旅游网站自由行路线数据缺失值、异常值、重复值的处理。

首先输入以下代码。

```
# 读取自由行路线数据表
import pandas as pd
df = pd.read_csv("D:/qunar_free_trip.csv")
df.head()
```

代码运行结果如图 9-65 所示。

	出发地	目的地	价格	节省	路线名	酒店	房间	去程航司	去程方式	去程时间	回程航司	回程方式	回程时间
0	北京	厦门	1866	492	北京-厦门3天2晚	入住厦门温特雅酒店 + 联合航空/首都航空往返机票	厦门温特雅酒店 舒适型 3.9分/5分	标准房(大床)(预付) 大床 不含早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15
1	北京	厦门	2030	492	北京-厦门3天2晚	入住厦门华美达长升大酒店 + 联合航空/首都航空往返机票	厦门华美达长升大酒店 4.1分/5分	标准房(错峰出游) 大/双床 双早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15
2	北京	厦门	2139	533	北京-厦门3天2晚	入住厦门毕思特酒店 + 联合航空/首都航空往返机票	厦门毕思特酒店 高档型 4.4分/5分	标准大床房(特惠) [双... 大床 双早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15
3	北京	厦门	2141	502	北京-厦门3天2晚	入住厦门翔鹭国际大酒店 + 联合航空/首都航空往返机票	厦门翔鹭国际大酒店 豪华型 4.4分/5分	高级大床房(含单早) 其他 单早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15
4	北京	厦门	2159	524	北京-厦门3天2晚	入住厦门京闽中心酒店 + 联合航空/首都航空往返机票	厦门京闽中心酒店 4.5分/5分	高级房(双床)(新春特... 双床 双早 1间2晚	联合航空 KN5927	直飞	16:55-19:45	首都航空 JD5376	直飞	22:15-01:15

图 9-65

然后输入以下代码，发现没有缺失值。

```
# 查看是否有缺失值
df.info()
```

代码运行结果如图 9-66 所示。

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 30821 entries, 0 to 30820
Data columns (total 13 columns):
出发地     30821 non-null object
目的地     30821 non-null object
价格      30821 non-null int64
节省      30821 non-null int64
路线名     30821 non-null object
酒店      30821 non-null object
房间      30821 non-null object
去程航司    30821 non-null object
去程方式    30821 non-null object
去程时间    30821 non-null object
回程航司    30821 non-null object
回程方式    30821 non-null object
回程时间    30821 non-null object
dtypes: int64(2), object(11)
memory usage: 3.1+ MB
```

图 9-66

接下来输入以下代码，发现有 130 个重复值。

```
# 查看是否有重复值
df.duplicated().value_counts()
```

代码运行结果如图 9-67 所示。

```
False    30691
True       130
dtype: int64
```

图 9-67

接下来输入以下代码。

```
# 移除重复值
df = df.drop_duplicates()
df.duplicated().value_counts()
```

代码运行结果如图 9-68 所示。

```
False    30691
dtype: int64
```

图 9-68

接下来输入以下代码。

```
# 查看描述性统计信息
df.describe()
```

代码运行结果如图 9-69 所示。

	价格	节省
count	30691.000000	30691.000000
mean	1734.980906	473.514548
std	649.396418	152.293192
min	541.000000	302.000000
25%	1254.000000	358.000000
50%	1644.000000	438.000000
75%	2043.000000	532.000000
max	6792.000000	1830.000000

图 9-69

接下来输入以下代码。

```
# 画出价格分布的直方图和箱形图
```

```
%matplotlib inline
import matplotlib as mpl
import matplotlib.pyplot as plt

fig, axes = plt.subplots(1, 2, figsize=(12, 5))
axes[0].hist(df["价格"],bins=20)
df.boxplot(column="价格",ax=axes[1])
fig.tight_layout()
```

代码运行结果如图 9-70 所示。

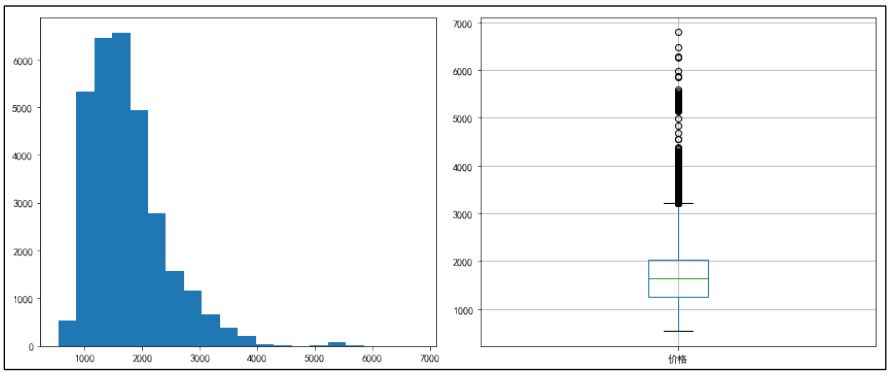

图 9-70

最后输入以下代码。

```
# 用均方差法找出价格异常值
d=df["价格"]
zscore = (d - d.mean())/d.std()
df['isOutlier'] = zscore.abs() > 3.5
print (df['isOutlier'].value_counts())
df[df['isOutlier']==True]
```

代码运行结果如图 9-71 所示，这里发现 139 个异常值。

```
False    30552
True       139
Name: isOutlier, dtype: int64
```

	出发地	目的地	价格	节省	路线名	酒店	房间	去程航司	去程方式	去程时间	回程航司	回程方式	回程时间	isOutlier
311	北京	丽江	4347	1056	北京-丽江3天2晚 | 入住丽江悦榕庄 + 首都航空往返机票	丽江悦榕庄 豪华型 4.7分/5分	豪华园景房别墅房(Vi... 大/双床 双早 1间2晚	首都航空 JD5215	直飞	21:30-01:05	首都航空 JD5182	直飞	06:05-09:25	True
1943	北京	三亚	4071	993	北京-三亚3天2晚 | 入住三亚太阳湾柏悦酒店 + 南方航空/海南航空往返机票	三亚太阳湾柏悦酒店 豪华型 4.7分/5分	柏悦双人客房（独家首日... 双床 双早 1间2晚	南方航空 CZ6716	直飞	19:00-23:10	海南航空 HU7280	直飞	19:55-23:35	True

图 9-71

9.4 时序数据处理

9.4.1 日期/时间数据转换

打印系统时间戳，代码如下。

```
import time
print(time.time())
```

代码运行结果如图 9-72 所示。

```
1496045526.6845787
```

图 9-72

时间戳是指格林威治时间 1970 年 01 月 01 日 00 时 00 分 00 秒(北京时间 1970 年 01 月 01 日 08 时 00 分 00 秒)起至现在的总秒数。

打印系统时间，代码如下。

```
print(time.localtime())
```

代码运行结果如图 9-73 所示。

```
time.struct_time(tm_year=2017, tm_mon=5, tm_mday=29, tm_hour=16, tm_min=19, tm_sec=48, tm_wday=0, tm_yday=149, tm_isdst=0)
```

图 9-73

然后输入以下代码。

```
print(time.strftime('%Y-%m-%d %X', time.localtime()))
```

代码运行结果如图 9-74 所示。

```
2017-05-29 16:19:48
```

图 9-74

将系统时间转换成时间戳，代码如下。

```
print(time.mktime(time.localtime()))
```

代码运行结果如图 9-75 所示。

```
1496045988.0
```

图 9-75

将时间戳转变成系统时间，代码如下。

```
print(time.strftime('%Y-%m-%d %X',time.localtime(1496044286.0)))
```

代码运行结果如图 9-76 所示。

```
2017-05-29 15:51:26
```

图 9-76

9.4.2　时序数据基础操作

首先，用 datetime 函数创建时间序列，代码如下。

```
import datetime
import numpy as np
import pandas as pd
pd.date_range(datetime.datetime(2017, 1, 1), periods=31)
```

代码运行结果如图 9-77 所示。

```
DatetimeIndex(['2017-01-01', '2017-01-02', '2017-01-03', '2017-01-04',
               '2017-01-05', '2017-01-06', '2017-01-07', '2017-01-08',
               '2017-01-09', '2017-01-10', '2017-01-11', '2017-01-12',
               '2017-01-13', '2017-01-14', '2017-01-15', '2017-01-16',
               '2017-01-17', '2017-01-18', '2017-01-19', '2017-01-20',
               '2017-01-21', '2017-01-22', '2017-01-23', '2017-01-24',
               '2017-01-25', '2017-01-26', '2017-01-27', '2017-01-28',
               '2017-01-29', '2017-01-30', '2017-01-31'],
              dtype='datetime64[ns]', freq='D')
```

图 9-77

然后输入以下代码。

```
pd.date_range("2017-1-1", periods=31) # 31 天
```

代码运行结果如图 9-78 所示。

```
DatetimeIndex(['2017-01-01', '2017-01-02', '2017-01-03', '2017-01-04',
               '2017-01-05', '2017-01-06', '2017-01-07', '2017-01-08',
               '2017-01-09', '2017-01-10', '2017-01-11', '2017-01-12',
               '2017-01-13', '2017-01-14', '2017-01-15', '2017-01-16',
               '2017-01-17', '2017-01-18', '2017-01-19', '2017-01-20',
               '2017-01-21', '2017-01-22', '2017-01-23', '2017-01-24',
               '2017-01-25', '2017-01-26', '2017-01-27', '2017-01-28',
               '2017-01-29', '2017-01-30', '2017-01-31'],
              dtype='datetime64[ns]', freq='D')
```

图 9-78

接下来输入以下代码。

```
# freq="H"表示按小时生成序列
pd.date_range("2017-5-1 00:00", "2017-5-1 12:00", freq="H")
```

代码运行结果如图 9-79 所示。

```
DatetimeIndex(['2017-05-01 00:00:00', '2017-05-01 01:00:00',
               '2017-05-01 02:00:00', '2017-05-01 03:00:00',
               '2017-05-01 04:00:00', '2017-05-01 05:00:00',
               '2017-05-01 06:00:00', '2017-05-01 07:00:00',
               '2017-05-01 08:00:00', '2017-05-01 09:00:00',
               '2017-05-01 10:00:00', '2017-05-01 11:00:00',
               '2017-05-01 12:00:00'],
              dtype='datetime64[ns]', freq='H')
```

图 9-79

接下来输入以下代码。

```
# index 是时间序列
ts1 = pd.Series(np.arange(31), index=pd.date_range("2017-1-1", periods=31))
ts1.head()
```

代码运行结果如图 9-80 所示。

```
2017-01-01    0
2017-01-02    1
2017-01-03    2
2017-01-04    3
2017-01-05    4
Freq: D, dtype: int32
```

图 9-80

接下来输入以下代码。

```
ts1["2017-1-3"] #找到索引对应的数据
```

代码运行结果如图 9-81 所示。

```
2
```

图 9-81

接下来输入以下代码。

```
ts1.index[2]    #打印第 2 个（从 0 开始）索引值
```

代码运行结果如图 9-82 所示。

```
Timestamp('2017-01-03 00:00:00', freq='D')
```

图 9-82

最后输入以下代码。

```
# 取出第 2 个索引对应的年月日
ts1.index[2].year, ts1.index[2].month, ts1.index[2].day
```

代码运行结果如图 9-83 所示。

```
(2017, 1, 3)
```

图 9-83

9.4.3　案例：天气数据分析与处理

1．时序分析

本案例针对第 3 章的天气数据做时序分析，首先输入以下代码。

```
data=pd.read_csv("D:/hz_weather.csv")
df=data[['日期','最高气温','最低气温']]
df.head()
```

代码运行结果如图 9-84 所示。

	最高气温	最低气温
日期		
2017-01-01	17	7
2017-01-02	16	8
2017-01-03	15	8
2017-01-04	15	11
2017-01-05	13	11

图 9-84

修改日期格式，并将日期设为索引（index），代码如下。

```
df.日期= pd.to_datetime(df.日期.values, format="%Y-%m-%d")
df = df.set_index('日期')   # 把日期设为 index
df.index[0]                 # 取出第 0 个索引对应的日期值
```

代码运行结果如图 9-85 所示。

```
Timestamp('2017-01-01 00:00:00')
```

图 9-85

接下来输入以下代码。

```
df.info()
```

代码运行结果如图 9-86 所示。

```
<class 'pandas.core.frame.DataFrame'>
DatetimeIndex: 118 entries, 2017-01-01 to 2017-04-30
Data columns (total 2 columns):
最高气温    118 non-null int64
最低气温    118 non-null int64
dtypes: int64(2)
memory usage: 2.8 KB
```

图 9-86

接下来输入以下代码。

```
df.index < "2017-2-1"   #返回一个布尔值数组
```

代码运行结果如图 9-87 所示。

```
array([ True,  True,  True,  True,  True,  True,  True,  True,  True,
        True,  True,  True,  True,  True,  True,  True,  True,  True,
        True,  True,  True,  True,  True,  True,  True,  True,  True,
        True,  True,  True,  True, False, False, False, False, False,
       False, False, False, False, False, False, False, False, False,
       False, False, False, False, False, False, False, False, False,
       False, False, False, False, False, False, False, False, False,
       False, False, False, False, False, False, False, False, False,
       False, False, False, False, False, False, False, False, False,
       False, False, False, False, False, False, False, False, False,
       False, False, False, False, False, False, False, False, False,
       False, False, False, False, False, False, False, False, False,
       False, False, False, False, False, False, False, False, False, False],  dtype=bool)
```

图 9-87

接下来输入以下代码。

```
# 提取 1 月份的温度数据
df_jan = df[(df.index >="2017-1-1") & (df.index < "2017-2-1")]
df_jan.info()
```

代码运行结果如图 9-88 所示。

```
<class 'pandas.core.frame.DataFrame'>
DatetimeIndex: 31 entries, 2017-01-01 to 2017-01-31
Data columns (total 2 columns):
最高气温    31 non-null int64
最低气温    31 non-null int64
dtypes: int64(2)
memory usage: 744.0 bytes
```

图 9-88

接下来输入以下代码。

```
df1_jan = df["2017-1-1":"2017-1-31"]# 设置起始日期和截止日期
```

```
df1_jan.info()
```

代码运行结果如图 9-89 所示。

```
<class 'pandas.core.frame.DataFrame'>
DatetimeIndex: 31 entries, 2017-01-01 to 2017-01-31
Data columns (total 2 columns):
最高气温    31 non-null int64
最低气温    31 non-null int64
dtypes: int64(2)
memory usage: 744.0 bytes
```

图 9-89

接下来输入以下代码。

```
# 只取月份
df.to_period('M').head()
```

代码运行结果如图 9-90 所示。

	最高气温	最低气温
日期		
2017-01	17	7
2017-01	16	8
2017-01	15	8
2017-01	15	11
2017-01	13	11

图 9-90

接下来输入以下代码。

```
df_month = df.to_period("M").groupby(level=0).mean()
# groupby 对 index 做聚合，再做均值 mean (level 指定索引层级)
df_month.head()
```

代码运行结果如图 9-91 所示。

	最高气温	最低气温
日期		
2017-01	10.870968	4.064516
2017-02	12.428571	3.821429
2017-03	15.000000	7.586207
2017-04	23.800000	13.833333

图 9-91

2．制作温度变化趋势图

在制图之前，先要介绍如何在 matplotlib 里支持中文作图，具体方法如下。

首先，修改 matplotlib 安装目录（Lib\site-packages\matplotlib\mpl-data）下的 matplotlibrc 配置文件，将 font.family 部分注释去掉，并且在 font.serif 和 font.sans-serif 支持字体中添加中文字体，如 SimHei（参见图 9-92）。

```
196 font.family          : sans-serif
197 #font.style           : normal
198 #font.variant         : normal
199 #font.weight          : medium
200 #font.stretch         : normal
201 # note that font.size controls default text sizes.  To configure
202 # special text sizes tick labels, axes, labels, title, etc, see the rc
203 # settings for axes and ticks. Special text sizes can be defined
204 # relative to font.size, using the following values: xx-small, x-small,
205 # small, medium, large, x-large, xx-large, larger, or smaller
206 #font.size            : 10.0
207 font.serif           : SimHei, DejaVu Serif, Bitstream Vera Serif, New Century Sc
208 font.sans-serif      : SimHei, DejaVu Sans, Bitstream Vera Sans, Lucida Grande, V
209 #font.cursive         : Apple Chancery, Textile, Zapf Chancery, Sand, Script MT,
210 #font.fantasy         : Comic Sans MS, Chicago, Charcoal, Impact, Western, Humor
211 #font.monospace       : DejaVu Sans Mono, Bitstream Vera Sans Mono, Andale Mono,
```

图 9-92

然后输入以下代码，进行作图。

```
%matplotlib inline
import matplotlib as mpl
import matplotlib.pyplot as plt
fig, ax = plt.subplots(1, 1, figsize=(12, 4))
df.plot(ax=ax)
```

代码运行结果如图 9-93 所示。

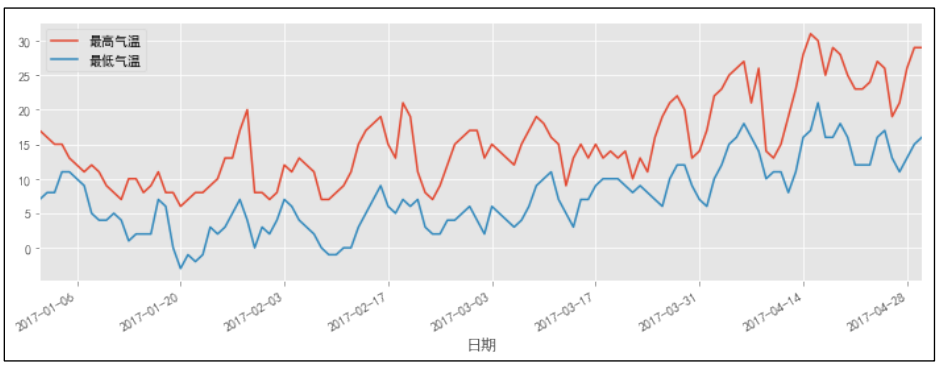

图 9-93

9.5 数据类型转换

在 Python 中区分文本（String）、整型（Int）等数据类型，不同数据类型之间可以转换。

首先读入并观察数据，代码如下。

```
import pandas as pd
df_pop = pd.read_csv("D:/european_cities.csv")
df_pop.head()
```

代码运行结果如图 9-94 所示。

	Rank	City	State	Population	Date of census/estimate
0	1	London[2]	United Kingdom	8,615,246	1 June 2014
1	2	Berlin	Germany	3,437,916	31 May 2014
2	3	Madrid	Spain	3,165,235	1 January 2014
3	4	Rome	Italy	2,872,086	30 September 2014
4	5	Paris	France	2,273,305	1 January 2013

图 9-94

然后查看字段的数据类型，代码如下。

```
type(df_pop.Population[0]) # 不是纯数值，是 string 型的
```

代码运行结果如图 9-95 所示。

```
str
```

图 9-95

接下来删除字段中的逗号，代码如下。

```
df_pop["NumericPopulation"] = df_pop.Population.apply(lambda x: int(x.
replace(",", "")))
# lambda 表示下面的内容是一个函数，对每一行用 apply 操作，去掉 population 每个元素的
# 逗号并转为 integer
# apply 很方便，不用循环
df_pop.head()
```

代码运行结果如图 9-96 所示。

	Rank	City	State	Population	Date of census/estimate	NumericPopulation
0	1	London[2]	United Kingdom	8,615,246	1 June 2014	8615246
1	2	Berlin	Germany	3,437,916	31 May 2014	3437916
2	3	Madrid	Spain	3,165,235	1 January 2014	3165235
3	4	Rome	Italy	2,872,086	30 September 2014	2872086
4	5	Paris	France	2,273,305	1 January 2013	2273305

图 9-96

读取 State 列中的前 3 个数据，代码如下。

```
df_pop["State"].values[:3]
```

代码运行结果如图 9-97 所示。

```
array([' United Kingdom', ' Germany', ' Spain'], dtype=object)
```

图 9-97

对 State 数据字段进行调整，代码如下。

```
df_pop["State"] = df_pop["State"].apply(lambda x: x.strip())
# 去掉 string 的前后的空格
df_pop.head()
```

代码运行结果如图 9-98 所示。

	Rank	City	State	Population	Date of census/estimate	NumericPopulation
0	1	London[2]	United Kingdom	8,615,246	1 June 2014	8615246
1	2	Berlin	Germany	3,437,916	31 May 2014	3437916
2	3	Madrid	Spain	3,165,235	1 January 2014	3165235
3	4	Rome	Italy	2,872,086	30 September 2014	2872086
4	5	Paris	France	2,273,305	1 January 2013	2273305

图 9-98

查看所有字段的数据类型，代码如下。

```
df_pop.dtypes
```

代码运行结果如图 9-99 所示。

```
Rank                        int64
City                       object
State                      object
Population                 object
Date of census/estimate    object
NumericPopulation           int64
dtype: object
```

图 9-99

在 pandas dataframe 中，dtype: object 表示文本（字符串）类型。

9.6 正则表达式

正则表达式，又称规则表达式（Regular Expression），在代码中常简写为 ReGex、RegExp 或 RE，它是计算机科学的一个概念。正则表达式通常被用来检索、替换符合某个模式（规则）的文本。

正则表达式由一些普通字符和一些元字符（metacharacters）组成。普通字符包括大小写的字母和数字，而元字符则具有特殊的含义，下面进行具体解释。

9.6.1　元字符与限定符

1．元字符（参见表 9-1）

表 9-1

元字符	描　　述
$	匹配输入字符串的结尾位置。如果设置了 RegExp 对象的 Multiline 属性，则$也匹配“\n”或“\r”。要匹配$字符本身，请使用\$
( )	标记一个子表达式的开始和结束位置。子表达式可以获取供以后使用。要匹配这些字符，请使用 \(和 \)
*	匹配前面的子表达式零次或多次。要匹配 * 字符，请使用 *
+	匹配前面的子表达式一次或多次。要匹配 + 字符，请使用 \+
.	匹配除换行符 \n 之外的任何单字符。要匹配 . ，请使用 \.
[	标记一个中括号表达式的开始。要匹配 [，请使用 \[
?	匹配前面的子表达式零次或一次，或指明一个非贪婪限定符。要匹配 ？字符，请使用 \?
\	将下一个字符标记为或特殊字符、或原义字符、或向后引用、或八进制转义符。例如，“n”匹配字符“n”，“\n”匹配换行符；序列“\\”匹配“\”，而“\(”则匹配“(”
^	匹配输入字符串的开始位置，除非在方括号表达式中使用，此时它表示不接受该字符集合。要匹配 ^ 字符本身，请使用 \^
{	标记限定符表达式的开始。要匹配 {，请使用 \{
|	指明两项之间的一个选择。要匹配 |，请使用 |

2．限定符（参见表 9-2）

表 9-2

字符	描　　述
*	匹配前面的子表达式零次或多次。例如，“zo*”能匹配“z”以及“zoo”。“*”等价于“{0,}”
+	匹配前面的子表达式一次或多次。例如，“zo+”能匹配“zo”以及“zoo”，但不能匹配“z”。“+”等价于“{1,}”
?	匹配前面的子表达式零次或一次。例如，“do(es)?”可以匹配“do”或“does”中的“do”。“?”等价于“{0,1}”
{n}	n 是一个非负整数。匹配确定的 n 次。例如，“o{2}”不能匹配“Bob”中的“o”，但是能匹配“food”中的两个“o”
{n,}	n 是一个非负整数。至少匹配 n 次。例如，“o{2,}”不能匹配“Bob”中的“o”，但能匹配“foooood”中的所有“o”。“o{1,}”等价于“o+”、“o{0,}”则等价于“o*”
{n,m}	m 和 n 均为非负整数，其中 n≤m。最少匹配 n 次且最多匹配 m 次。例如“o{1,3}”将匹配“fooooood”中的前 3 个“o”。“o{0,1}”等价于“o?”。注意在逗号和两个数之间不能有空格

9.6.2 案例：用正则表达式提取网页文本信息

接下来使用第 2 章的数据作为案例，提取文本信息。

首先输入以下代码。

```
import pandas as pd
df = pd.read_csv("D:/getlinks.csv")
df.head()
```

代码运行结果如图 9-100 所示。

	title	link
0	网民最喜欢的旅游目的地榜单出炉	http://cntour.cn/news/4221/
1	让生活更幸福是旅游业的使命	http://cntour.cn/news/4212/
2	"一带一路"国家中东欧游客增两倍	http://cntour.cn/news/4202/
3	旅游业改革开启旅游强国新篇章	http://cntour.cn/news/4191/

图 9-100

在 pandas 中使用 link.str.extract 方法提取数字，它的第一个参数是正则表达式，括号表示要提取的部分，代码如下。

```
df.link.str.extract('(\d+)')
```

代码运行结果如图 9-101 所示。

```
0    4221
1    4212
2    4202
3    4191
Name: link, dtype: object
```

图 9-101

假如要提取多个数据，则可以使用多个括号，代码如下。

```
df.link.str.extract('(.*)/(\d+)')
```

代码运行结果如图 9-102 所示。

	0	1
0	http://cntour.cn/news	4221
1	http://cntour.cn/news	4212
2	http://cntour.cn/news	4202
3	http://cntour.cn/news	4191

图 9-102

如果想要让输出的结果包含变量名（列名），则可以使用下面的写法。

```
df.link.str.extract('(?P<URL>.*)/(?P<ID>\d+)')
```

代码运行结果如图 9-103 所示。

	URL	ID
0	http://cntour.cn/news	4221
1	http://cntour.cn/news	4212
2	http://cntour.cn/news	4202
3	http://cntour.cn/news	4191

图 9-103

第 10 章

综合应用实例

10.1 按性价比给用户推荐旅游产品

本案例主要介绍如何获取大量的旅游产品，并通过产品信息计算性价比，按性价比给用户推荐产品。这里通过预测价格和实际价格之比来判断性价比，例如甲花了 100 元买了商品 A，随后请乙估算商品 A 的价格，如果乙估了 200 元，那么甲会觉得买值了；如果乙估了 50 元，那么甲会觉得买亏了。

其业务逻辑如图 10-1 所示。

图 10-1

其流程设计如图 10-2 所示。

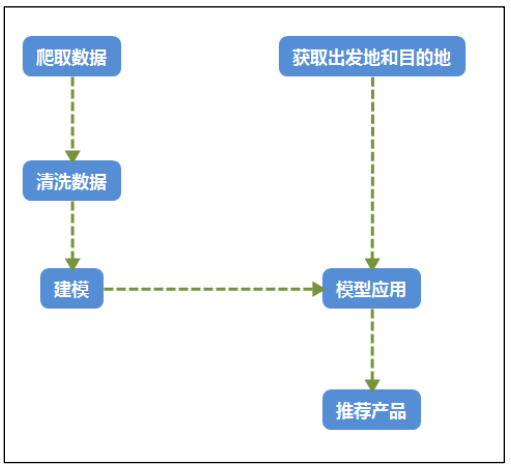

图 10-2

10.1.1　数据采集

数据采集的具体过程如下。

（1）编写某旅游网站自由行路线搜索结果爬虫，如搜索“杭州”到“丽江”的自由行路线，连续下拉滚动条 50 次获取前 100 多条推荐路线。

（2）对于搜索结果中每个路线，首先抓其取路线标题，然后单击进入详情页抓取住宿信息，如“酒店评分”（如 4.5 分、5.0 分）、“酒店等级”（如舒适型、高档型）等。

（3）将数据写入 qunar_routes.csv 文件。

完整爬虫代码如下。

```
import requests
import json
import urllib.request
import time
import csv
import random
from selenium import webdriver
from selenium.webdriver.common.by import By
from selenium.webdriver.support.ui import WebDriverWait
from selenium.webdriver.support import expected_conditions as EC
from selenium.webdriver.common.action_chains import ActionChains
from selenium.webdriver.common.keys import Keys
```

```
def globalVals():
    global driver
    global driver_

    driver = webdriver.Chrome()
    driver_ = webdriver.Chrome()


def init_csv():
    global f
    global writer
    csvFile = "D:/qunar_routes.csv"
    # 打开文件后如果乱码，则将 utf-8 改成 gb18030
    f = open(csvFile, "w", newline="", encoding='utf-8')
    writer = csv.writer(f)
    writer.writerow(["出发地","目的地","路线信息","酒店信息"])


def close_csv():
    global f
    f.close()


def dump_routes_csv(dep,arr):
    global driver
    global driver_
    global writer

    # 定位所有路线信息
    routes = driver.find_elements_by_css_selector(".item.g-flexbox.list-item")
    for route in routes:
        try:
            print("\nroute info:%s" % route.text)
            # 获取路线详情页 URL
            url = route.get_attribute("data-url")
            print("url:%s" % url)

            #在另一个浏览器对象打开路线详情页
            driver_.get(url)
            time.sleep(random.uniform(2, 3))

            if "fhtouch" in url: # 机酒自由行
                try:
                    # we have to wait for the page to refresh
```

```
                    WebDriverWait(driver_, 10).until(
                        EC.presence_of_element_located((By.CSS_SELECTOR,
"#allHotels")))
                    source=driver_.find_element_by_css_selector('#main-page')
                    target=driver_.find_element_by_css_selector('#allHotels')
                except:
                    print(str(e))
                    continue
            else:             # 自由行
                try:
                    # 等待页面刷新成功
                    WebDriverWait(driver_, 10).until(
                        EC.presence_of_element_located((By.CSS_SELECTOR,
".m-ball.m-ball-back")))
                    source=driver_.find_element_by_css_selector('.flex.
scrollable')
                    target=driver_.find_element_by_css_selector('.m-ball.m-
ball-back')
                except:
                    print(str(e))
                    continue

            # 路线详情页需须通过 drag_and_drop 动作获得焦点，否则[Page Down]键无效
            ActionChains(driver_).drag_and_drop(source, target).perform()

            for i in range(3):
                # 模拟[Page Down]键的输入，实现下拉滚动条动作（3 次）
                ActionChains(driver_).send_keys(Keys.PAGE_DOWN).perform()

            # 路线详情页下拉滚动条后才可定位到下面的元素
            try:
                # we have to wait for the page to refresh
                WebDriverWait(driver_, 10).until(
                    EC.presence_of_element_located((By.CSS_SELECTOR,
".tit .score")))
            except Exception as e:
                print(str(e))
                continue

            try:
                # 获取酒店评分
                rating = driver_.find_element_by_css_selector(".tit .score")

                # 获取酒店类型
```

```
                type=driver_.find_element_by_css_selector(".tit
+ .tag-list > .g-tag.solid")

                # 拼接成酒店信息
                hotel = '\n'.join([rating.text, type.text])
                print("hotel info:%s" % hotel)
            except Exception as e:
                print(str(e))
                continue

            # 将这一条路线信息写入 CSV 文件
            writer.writerow([dep, arr, route.text, hotel])
        except:
            continue


    if __name__ == "__main__":
        globalVals()
        init_csv()
        dep_cities = ["杭州"]

        for dep in dep_cities:
            strhtml   =   requests.get('https://m.dujia.qunar.com/golfz/sight/
arriveRecommend?dep=' + urllib.request.quote(dep) + '&exclude=&extensionImg=
255,175')
            arrive_dict = json.loads(strhtml.text)
            for arr_item in arrive_dict['data']:
                # 本例只爬取国内自由行路线，如需爬取国际路线，可将下面两行注释掉
                if arr_item['title'] != "国内":
                    continue

                for arr_item_1 in arr_item['subModules']:
                    for query in arr_item_1['items']:
                        # 本例只爬取杭州—丽江的自由行路线，如需爬取杭州—全国路线，可将下
                        # 面两行注释掉
                        if query['query'] != "丽江":
                            continue

                        # 打开移动端自由行路线搜索结果页面
                        driver.get("https://touch.dujia.qunar.com/p/ list?cfrom=
zyx&dep=" + urllib.request.quote(dep) +  "&query=" + urllib.request.quote
(query['query']) + "%e8%87%aa%e7%94%b1%e8%a1%8c&it=n_index_free")
                        try:
                            # we have to wait for the page to refresh
```

```
                    WebDriverWait(driver,      10).until(EC.presence_of_
element_located((By.CLASS_NAME, "item g-flexbox list-item ")))
                except Exception as e:
                    print(str(e))
                    raise

                print("dep:%s arr:%s" % (dep, query["query"]))

                # 连续下拉滚动条 50 次获取更多路线列表
                for i in range(50):
                    time.sleep(random.uniform(2, 3))
                    print("page %d" % (i+1))
                    # 模拟 page down 键的输入，实现下拉滚动条动作
                    ActionChains(driver).send_keys(Keys.PAGE_DOWN).perform()

                # 将出发地-目的地的自由行路线写入 CSV 文件
                dump_routes_csv(dep, query["query"])

    close_csv()
    driver.close()
    driver_.close()
```

PyCharm 运行输出结果如图 10-3 所示。

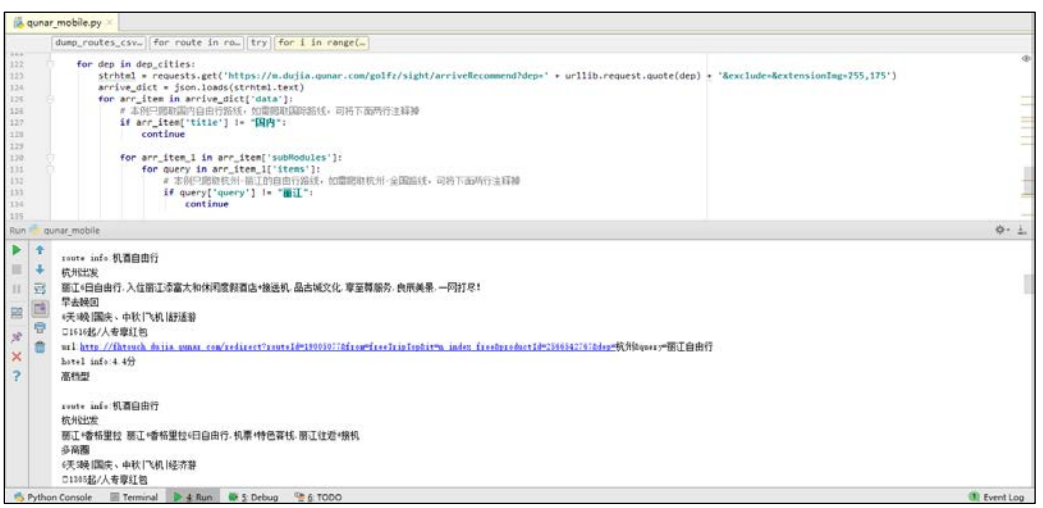

图 10-3

10.1.2　数据清洗、建模

数据清洗、建模的具体过程如下。

（1）编写数据清洗及线性回归建模程序，得到 R^2 为 0.886 的模型。

（2）将性价比定义为“预测价格”和“实际价格”的比值，将“性价比”从高到低排序，找出性价比最高的路线。

线性回归建模程序代码如下。

```
    import pandas as pd
    import matplotlib.pyplot as plt
    import statsmodels.api as sm

    # 读取路线信息 CSV 文件
    df = pd.read_csv("D:/qunar_routes.csv")
    print (df.head())
    print (df.info())

    # 从路线信息中提取天数、价格信息
    df["天数"]=df.路线信息.str.extract('(\d+)天\d+晚').apply(lambda x: int(x))
    df["价格"]=df.路线信息.str.extract('(\d+)起/人').apply(lambda x: int(x))

    # 从酒店信息中提取评分、等级信息
    df["酒店评分"]=df.酒店信息.str.extract('(\d\.\d)分').apply(lambda x:
float(x))
    df["酒店等级"]=df.酒店信息.str.extract('\n(.*)')

    print (df.head())
    print (df.info())

    # 将酒店等级信息由文本型映射成数值型
    class_map = {"其他":0,"经济型":1,"舒适型":2,"高档型":3,"豪华型":4}
    df["酒店等级"]=df["酒店等级"].map(class_map)

    # 对变量画直方图，查看是否有异常值
    fig, axes = plt.subplots(1, 3, figsize=(12, 4))
    df["酒店等级"].plot(ax=axes[0], kind='hist', title="酒店等级")
    df["酒店评分"].plot(ax=axes[1], kind='hist', title="酒店评分")
    df["价格"].plot(ax=axes[2], kind='hist', title="价格")

    #提取自变量 X,因变量 y
    X,y = df.ix[:,4:-1].values, df.ix[:,-1].values

    # 拟合 OLS 线性回归模型
    ols = sm.OLS(y,X)
    result = ols.fit()

    # 查看拟合效果，R2=0.886
    print (result.summary())
```

```
# 用训练好的线性回归模型来预测路线价格
y_pred = result.predict(X)

# 性价比定义为预测价格和实际价格的比值
ratio = y_pred/y
df["性价比"] = ratio

# 按性价比从高到低排序
print(df.sort_values("性价比", ascending=False))
```

代码运行结果如图 10-4 和图 10-5 所示。

OLS Regression Results

Dep. Variable:	y	R-squared:	0.886
Model:	OLS	Adj. R-squared:	0.883
Method:	Least Squares	F-statistic:	302.2
Date:	Tue, 30 May 2017	Prob (F-statistic):	6.47e-55
Time:	13:42:13	Log-Likelihood:	-1026.0
No. Observations:	120	AIC:	2058.
Df Residuals:	117	BIC:	2066.
Df Model:	3		
Covariance Type:	nonrobust		

	coef	std err	t	P>|t|	[95.0% Conf.	Int.]
x1	243.8182	71.514	3.409	0.001	102.188	385.448
x2	140.5419	96.623	1.455	0.148	-50.815	331.899
x3	592.0773	81.942	7.226	0.000	429.796	754.359

图 10-4

	出发地	目的地	路线信息	酒店信息	天数	酒店评分	酒店等级	价格	性价比
11	杭州	丽江	自由行\n昆明+大理+丽江+香格里拉 云南旅游新模式，分离试旅游。丽江自由行，云南/大理/丽...	4.1分\n高档型	10	4.1	3	2180	2.197539
4	杭州	丽江	机酒自由行\n丽江5日自由行,入住丽江听心祥和院+接送机\n5天4晚|天天出发|飞机|舒适游...	4.7分\n高档型	5	4.7	3	1740	2.101075
1	杭州	丽江	机酒自由行\n丽江6日自由行,入住丽江添富太和休闲度假酒店+接送机,品古城文化,享至尊服务,...	4.4分\n高档型	6	4.4	3	1872	2.060644
0	杭州	丽江	机酒自由行\n丽江5日自由行,入住丽江添富太和休闲度假酒店+接送机,品古城文化,享至尊服务,...	4.4分\n高档型	5	4.4	3	1888	1.914040
79	杭州	丽江	机酒自由行\n昆明+丽江+香格里拉 杭州飞昆明5日+N天自由休闲游，任意组合丽江/香格里拉/...	4.8分\n舒适型	5	4.8	2	1680	1.832052
2	杭州	丽江	机酒自由行\n丽江+香格里拉 丽江+香格里拉6日自由行,机票+特色客栈,丽江往返+接机\n特...	4.4分\n经济型	6	4.4	1	1517	1.762275
119	杭州	丽江	自由行\n昆明+大理+丽江 双廊精选双飞昆明大理丽江自由行3+N天随意搭配+旅游达人推荐吃喝...	4.1分\n高档型	6	4.1	3	2199	1.735045
118	杭州	丽江	自由行\n直飞丽江5天4晚自由行+N天自由行+特色客栈+接送机服务+20公里免费用车\n新城...	4.1分\n高档型	5	4.1	3	2110	1.692675
3	杭州	丽江	机酒自由行\n丽江+大理 丽江、大理双城6天自由行,3晚丽江特色客栈,2晚大理洱海边客栈,赠...	4.4分\n经济型	6	4.4	1	1612	1.658419
35	杭州	丽江	自由行\n<双飞往返丽江>丽江一地+机场接送 5天自由行 管家式服务（内附完整攻略）\n大研...	4.9分\n舒适型	5	4.9	2	1866	1.656967
106	杭州	丽江	自由行\n丽江+大理+香格里拉 <双飞往返丽江>丽江、香格里拉、泸沽湖、大理9天自由行管家式...	4.9分\n舒适型	9	4.9	2	2488	1.634716

图 10-5

10.2 通过热力图分析为用户提供出行建议

笔者在 9 月份爬取了某旅游网站热门景点地理位置、销量信息，利用百度地图 API 生成热力图，通过热力图了解各个景区的负荷情况，从而给用户提供出行建议。

百度地图 API Key 申请方法如下。

首先访问百度地图开放平台：http://lbsyun.baidu.com/。

然后单击页面下方的“申请密钥”按钮（参见图 10-6），这里需要登录百度账号。

图 10-6

登录帐号后便可以进入百度地图 LBS 开放平台（参见图 10-7）。

（1）选择“创建应用”命令。

（2）应用名称处，可以随意填写，如“热力图”。

（3）在启用服务处，勾选“JavaScript API”和“Geocoding API v2”复选框。

（4）在 Referer 白名单处，建议填*，方便在不同的电脑上访问。

（5）单击“提交”按钮。

进入应用列表页面，可以看到新创建的应用“热力图”的 API Key（AK），如图 10-8 所示。

图 10-7

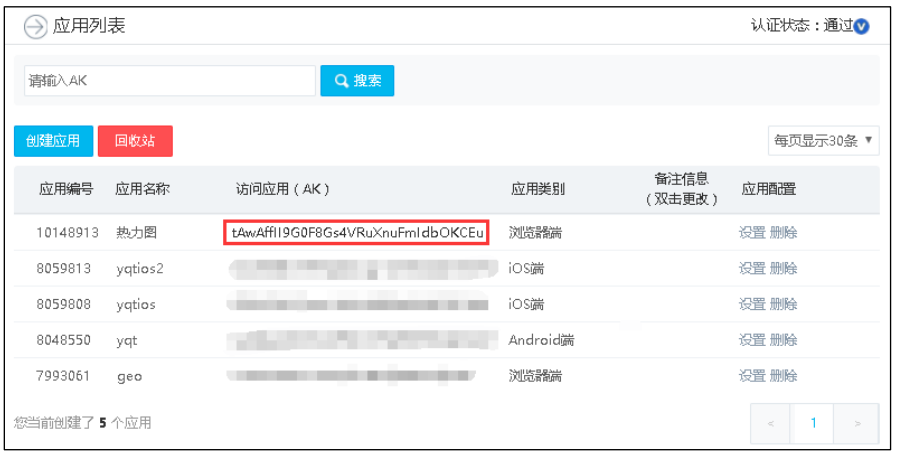

图 10-8

接下来通过 Geocoding API 将景点地址信息转换为经纬度信息，如图 10-9 所示。

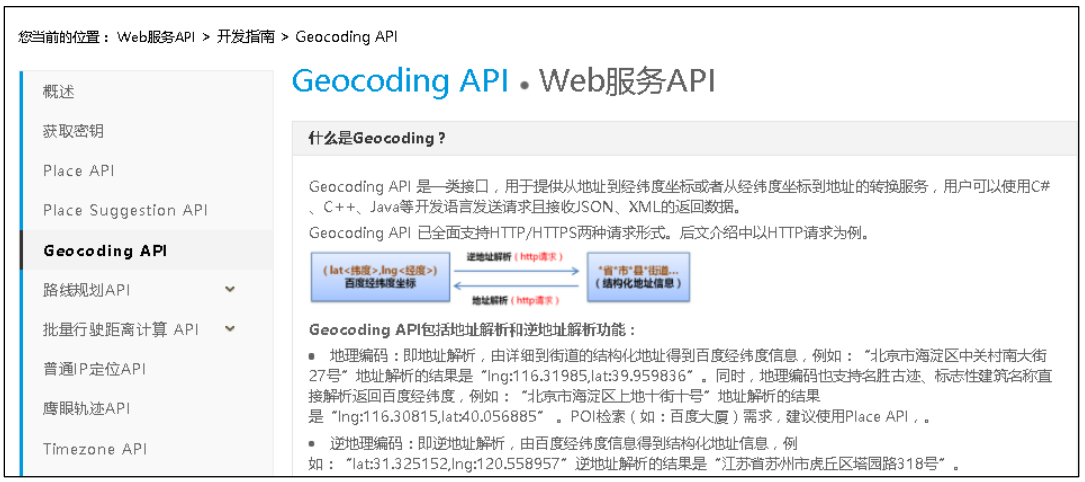

图 10-9

下面通过 JavaScript API 在网页中调用百度地图 Heatmap_min.js 将 JSON 数据渲染成热力图，如图 10-10 所示。

图 10-10

可访问下面网址查看热力图示例 HTML 代码。

http://developer.baidu.com/map/jsdemo.htm#c1_15

方框内是热力地图 JSON 源数据，如图 10-11 所示。

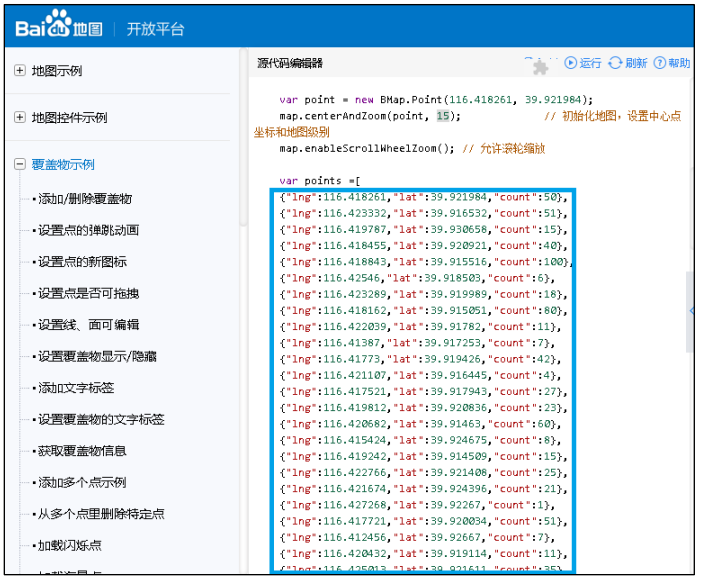

图 10-11

10.2.1　某旅游网站热门景点爬虫代码（qunaer_sights.py）

爬取时间为 2017 年 9 月 15 日，获取当月热门景点门票销量数据，代码如下。

```
import requests
from bs4 import BeautifulSoup
import pandas as pd
import time
import random
import urllib.parse
import json
import csv


# 读取上次爬取的 CSV 文件，以便断点续爬
def init_df():
    global df_sights
    try:
        df_sights = pd.read_csv("D:/qunaer_sights.csv")
    except:
        df_sights = pd.DataFrame()


# 初始化 CSV writer，第一次需写入列名
```

```
    def init_csv():
        global f
        global writer
        global df_sights
        csvFile = "D:/qunaer_sights.csv"
        f = open(csvFile, "a+", newline="", encoding='utf-8')
        writer = csv.writer(f)
        if df_sights.columns.empty:
            writer.writerow(["景点名", "等级", "地址", "介绍", "热度", "价格", "月
销量", "经度", "纬度"])


    # 程序结束前关闭 CSV 文件
    def close_csv():
        global f
        f.close()


    # 调用百度地图 API 获取景点地址对应的经纬度
    def get_geo_info(address):
        geo_url = "http://api.map.baidu.com/geocoder/v2/?"
        geo_params = {
            "output": "json",
            "ak": "tAwAffII9G0F8Gs4VRuXnuFmIdbOKCEu" # 替换成自己的百度地图 API Key
        }

        # 更新 url 中的地址参数
        geo_params.update({"address": address})
        data = urllib.parse.urlencode(geo_params)
        cur_geo_url = geo_url + data
        geo_resp = requests.get(cur_geo_url)

        json_data = json.loads(geo_resp.text)

        # 调用成功，获取 JSON data 中的经纬度信息
        if json_data["status"] == 0:
            longitude = json_data["result"]["location"]["lng"]
            latitude = json_data["result"]["location"]["lat"]
        else:
            longitude = ""
            latitude = ""

        return longitude, latitude
```

```
    # 抓取某旅游网站热门景点销量信息
    def dump_qunaer_sights(pages):
        global df_sights
        global writer
        base_url = "http://piao.qunar.com/ticket/list.htm?keyword=热门景点
&page="

        for i in range(pages):
            print("page:{0}".format(i + 1))
            url = base_url + str(i + 1)
            resp = requests.get(url)
            time.sleep(random.uniform(1, 3))

            # 通过 BeautifulSoup 解析当前页面 HTML，获取景点列表信息
            soup = BeautifulSoup(resp.text, 'lxml')
            sight_list = soup.select('.sight_item_detail')

            for sight in sight_list:
                # 获取景点名
                name = sight.select('.name')[0].text
                # 如该景点已存在 CSV 文件中，则跳过该页，继续爬取下一页（断点续爬）
                if not df_sights.empty and not df_sights[df_sights["景点名"] ==
name].empty:
                    break

                # 获取景点等级
                try:
                    level = sight.select('.level')[0].text.replace("景区", "")
                except:
                    level = ""

                # 获取景点地址
                address=sight.select('.address.color999 span')[0].text.replace
("地址：", "")

                # 获取景点介绍
                intro = sight.select('.intro.color999')[0].text

                # 获取景点热度
                star = sight.select('.product_star_level em span')[0].text.
replace("热度 ", "")

                # 获取门票价格、月销量
                try:
```

```
                price = sight.select('.sight_item_price em')[0].text
                sales = sight.select('.hot_num')[0].text
            except:
                continue

            # 将景点地址转换为经纬度
            longitude, latitude = get_geo_info(address)

            # 向 CSV 文件中插入一条景点信息
            sight_item = [name, level, address, intro, star, price, sales,
longitude, latitude]
            print(sight_item)
            writer.writerow(sight_item)


if __name__ == "__main__":
    init_df()
    init_csv()
    dump_qunaer_sights(pages=400)
    close_csv()
```

PyCharm 运行结果如图 10-12 所示。

图 10-12

10.2.2 提取 CSV 文件中经纬度和销量信息

提取信息将其转化为 JSON 数据打印（extract_json.py）

首先输入以下代码。

```
import pandas as pd
import json
df = pd.read_csv("D:/qunaer_sights.csv")
points = []
df = df[["经度","纬度","月销量"]]
for item in df.values:
    points.append({"lng":item[0],"lat":item[1],"count":item[2]})
str=json.dumps(points)
print(str)
```

PyCharm 运行结果如图 10-13 所示。

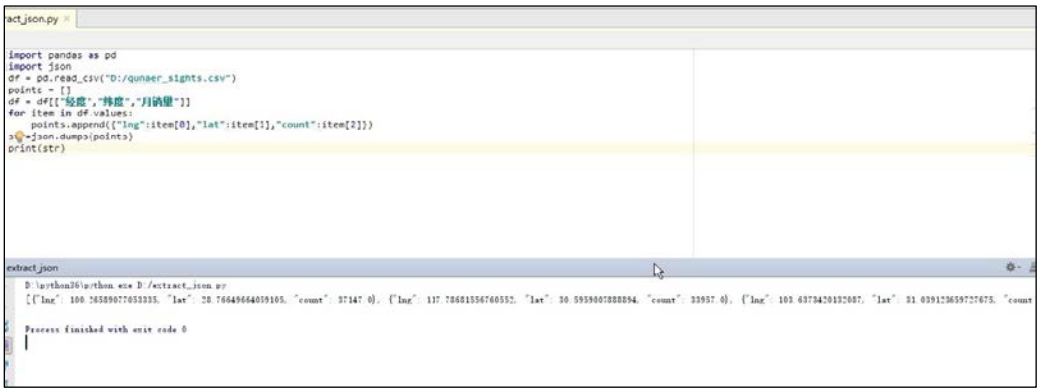

图 10-13

10.2.3　创建景点门票销量热力地图 HTML 文件

打开记事本输入 HTML，将加粗的 API key 替换成百度地图 API Key，代码如下。

```
<!DOCTYPE html>
<html>
<head>
    <meta http-equiv="Content-Type" content="text/html; charset=utf-8" />
    <meta name="viewport" content="initial-scale=1.0, user-scalable=no" />
    <script  type="text/javascript"  src="http://api.map.baidu.com/api?v=
2.0&ak=tAwAffII9G0F8Gs4VRuXnuFmIdbOKCEu"></script>
    <script type="text/javascript" src="http://api.map.baidu.com/library/
Heatmap/2.0/src/Heatmap_min.js"></script>
    <title>热力图功能示例</title>
    <style type="text/css">
        ul,li{list-style: none;margin:0;padding:0;float:left;}
        html{height:100%}
```

```
            body{height:100%;margin:0px;padding:0px;font-family:"微软雅黑";}
            #container{height:100%;width:100%;}
        </style>
    </head>
    <body>
        <div id="container"></div>
    </body>
    </html>
    <script type="text/javascript">
        var map = new BMap.Map("container");         // 创建地图实例

        var point = new BMap.Point(110, 37.5);
        map.centerAndZoom(point, 5);         // 初始化地图，设置中心点坐标和地图级别
        map.enableScrollWheelZoom(); // 允许通过滚轮缩放

        var points = [{"lng": 100.26589077053335, "lat": 28.76649664059105,
"count": 37147.0}, {"lng": 117.78681556760552, "lat": 30.5959007888894, "count":
33957.0}];  //这里需填写上一步中打印出的 JSON 数据（约 6000 条）

        if(!isSupportCanvas()){
            alert('热力图目前只支持有 canvas 支持的浏览器，您所使用的浏览器不能使用热力图
功能~')
        }
        //详细的参数,可以查看 heatmap.js 的文档 https://github.com/pa7/heatmap.
js/blob/master/README.md
        //参数说明如下:
        /* visible 热力图是否显示,默认为 true
         * opacity 热力的透明度,1-100
         * radius 势力图的每个点的半径大小
         * gradient  {JSON} 热力图的渐变区间 . gradient 如下所示
         * {
                .2:'rgb(0, 255, 255)',
                .5:'rgb(0, 110, 255)',
                .8:'rgb(100, 0, 255)'
            }
            其中 key 表示插值的位置，0~1；value 为颜色值
         */
        heatmapOverlay = new BMapLib.HeatmapOverlay({"radius":8});
        map.addOverlay(heatmapOverlay);
        heatmapOverlay.setDataSet({data:points,max:100});
        heatmapOverlay.show();
        //是否显示热力图
        function openHeatmap(){
            heatmapOverlay.show();
```

```
        }
        function closeHeatmap(){
            heatmapOverlay.hide();
        }
        //closeHeatmap();
        function setGradient(){
            /*格式如下所示:
            {
                0:'rgb(102, 255, 0)',
                .5:'rgb(255, 170, 0)',
                1:'rgb(255, 0, 0)'
            }*/
            var gradient = {};
            var colors = document.querySelectorAll("input[type='color']");
            colors = [].slice.call(colors,0);
            colors.forEach(function(ele){
                gradient[ele.getAttribute("data-key")] = ele.value;
            });
            heatmapOverlay.setOptions({"gradient":gradient});
        }
        //判断浏览区是否支持 canvas
        function isSupportCanvas(){
            var elem = document.createElement('canvas');
            return !!(elem.getContext && elem.getContext('2d'));
        }
    </script>
```

输入 HTML 后，将文件保存，并重命名为 heat.html（注意后缀名要将 txt 修改成 html），用浏览器打开 heat.html，查看景点人气（门票月销量）热力图。

可以直接扫描二维码查看本例生成的热力图。

从图中可发现北京、江浙沪、广州、青岛、四川等地是游客扎堆的地方。

放大地图后，可以观察具体某个省份或某个城市的景区分布，国庆期间如果不想感受人潮涌动，那么可以避开这些过于热门的景点，转而选择一些相对小众的去处。以笔者所在的杭州为例，国庆期间杭州游客爆满，上海、苏州游客也很多，反而东边的宁波、舟山游客会少一些，去宁波、舟山吃海鲜大餐也是个不错的选择。本例只采集了一个平台的数据，最好是采集更多线上旅行电商的数据，然后再画出国庆出行热力图。

第 11 章

数据可视化

先准备好数据，以某电商网站商品数据为例，代码如下。

```
import pandas as pd
df = pd.read_csv("D:/taobao_data.csv")
df.head()
```

代码运行结果如图 11-1 所示。

	商品	价格	成交量	卖家	位置
0	新款中老年女装春装雪纺打底衫妈妈装夏装中袖宽松上衣中年人t恤	99.0	16647	夏亲凤凰旗舰店	江苏
1	中老年女装清凉两件套妈妈装夏装大码短袖T恤上衣雪纺衫裙裤套装	286.0	14045	夏洛特的文艺	上海
2	母亲节衣服夏季妈妈装夏装套装短袖中年人40-50岁中老年女装T恤	298.0	13458	云新旗舰店	江苏
3	母亲节衣服中老年人春装女40岁50中年妈妈装套装夏装奶奶装两件套	279.0	13340	韶妃旗舰店	浙江
4	中老年女装春夏装裤大码 中年妇女40-50岁妈妈装夏装套装七分裤	59.0	12939	千百亲旗舰店	江苏

图 11-1

删除“商品”和“卖家”两列，并根据位置对数值字段求均值，进行分组汇总，最后根据成交量均值降序排序。

```
df_mean = df.drop(["商品","卖家"], axis=1).groupby("位置").mean().sort_
values("成交量", ascending=False)
```

```
df_mean
# drop （默认 axis=0）是删掉行, axis=1 是删掉列
# groupby 汇总
```

代码运行结果如图 11-2 所示。

	价格	成交量
位置		
江苏	223.611364	7030.909091
上海	161.200000	6801.500000
湖北	254.714286	6182.000000
河北	152.000000	6050.666667
河南	119.000000	5986.000000
浙江	290.428571	5779.500000
广东	326.000000	5164.000000
北京	150.000000	4519.333333

图 11-2

11.1 matplotlib

matplotlib 是 Python 中非常出色的可视化库，能轻松应对大多数画图需求。

11.1.1 画出各省份平均价格、各省份平均成交量柱状图

首先输入以下代码。

```
%matplotlib inline
import matplotlib as mpl
import matplotlib.pyplot as plt

mpl.style.use('ggplot')
fig, (ax1, ax2) = plt.subplots(1, 2, figsize=(12, 4))
df_mean.价格.plot(kind='barh', ax=ax1)
ax1.set_xlabel("各省份平均价格")
df_mean.成交量.plot(kind='barh', ax=ax2)
ax2.set_xlabel("各省份平均成交量")
fig.tight_layout()
```

代码运行结果如图 11-3 所示。

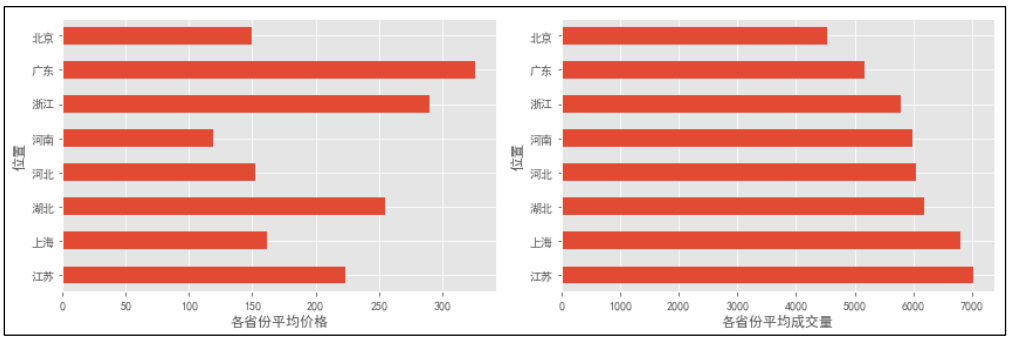

图 11-3

在 Anaconda 中，大多数的库都不需要安装，因此使用起来非常方便。

在调用 Matplotlib 的时候有（4）个步骤，如下所示。

（1）设定画图背景样式，将画图的背景样式设置成 ggplot。

ggplot 是一个非常出色的画图库，当然这里不是调用这个库，只是在 Matplotlib 中集成了这个库的画图风格（包含背景、配色等）。这里将画布风格设置成 ggplot 风格，代码如下。

```
mpl.style.use('ggplot')
```

（2）设定画布。

设定一张名叫 fig 的画布，将这个大画布分成两个小画布分别命名为 ax1 和 ax2。figsize 是设定了 fig 画布的大小为 12×4 点（point），代码如下。

```
fig, (ax1, ax2) = plt.subplots(1, 2, figsize=(12, 4))
```

（3）画图及设定元素。

画图只需要在数据集后用.plot 方法就可以画图了，kind='barh'表示画一张条形图，ax=ax1 表示这张条形图画在 ax1 这张子画布上，可以用 set_xlabel 设定 *X* 轴标签，代码如下。

```
df_mean.价格.plot(kind='barh', ax=ax1)
ax1.set_xlabel("各省份平均价格")
```

（4）自动调整格式。

设定好图表元素后，使图表自动调整格式，代码如下。

```
fig.tight_layout()
```

11.1.2 画出各省份平均成交量折线图、柱状图、箱形图和饼图

在观察数据分布的时候可以用折线图、柱状图、箱形图和饼图，在制图时可以输入以下代码。

```
fig, axes = plt.subplots(2, 2, figsize=(10, 10))
s=df_mean.成交量
```

```
s.plot(ax=axes[0][0], kind='line', title="line")
s.plot(ax=axes[0][1], kind='bar', title="bar")
s.plot(ax=axes[1][0], kind='box', title="box")
s.plot(ax=axes[1][1], kind='pie', title="pie")
fig.tight_layout()
```

代码运行结果如图 11-4 所示。

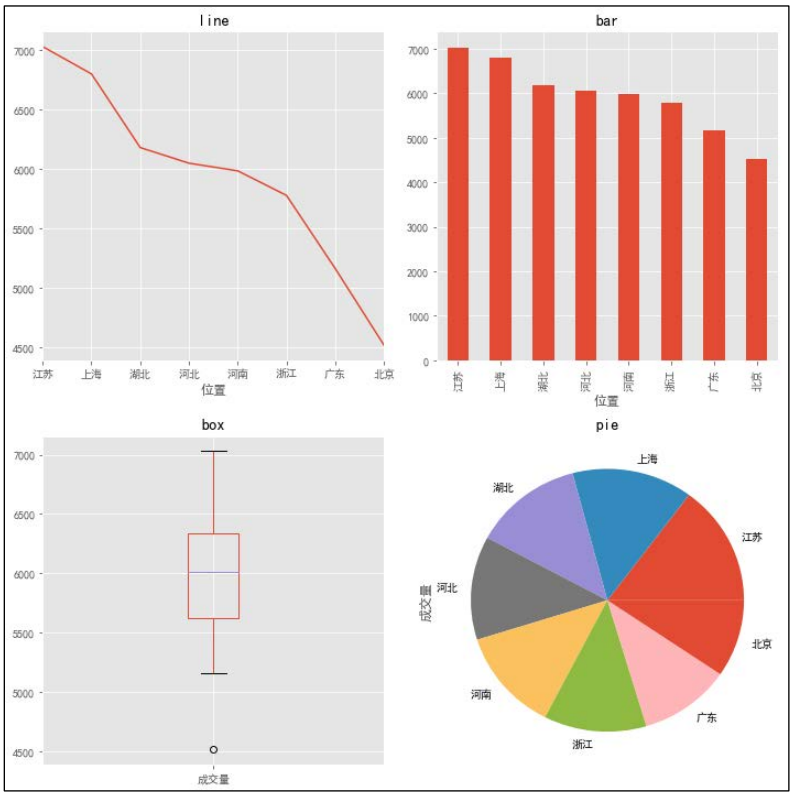

图 11-4

- 其中，kind='line'表示线图，kind='bar'表示柱状图，kind='box'表示箱形图，kind='pie'表示饼图。
- 其中 axes[0][0]代表第一行第一列，axes[0][1]代表第一行第二列。

接下来指定一个 2×2 布局的正方形（figsize=(10, 10)）画布，相当于一个二维数组，代码如下。

```
fig, axes = plt.subplots(2, 2, figsize=(10, 10))
```

11.1.3　画出价格与成交量的散点图

散点图一般用于观察两个度量之间的分布情况，以便研究两者之间的关系。首先输入下面代码，观察画图效果。

```
fig, ax = plt.subplots(1, 1, figsize=(12, 4))
ax.scatter(df.价格,df.成交量)
ax.set_xlabel("价格")
ax.set_ylabel("成交量")
```

代码运行结果如图 11-5 所示。

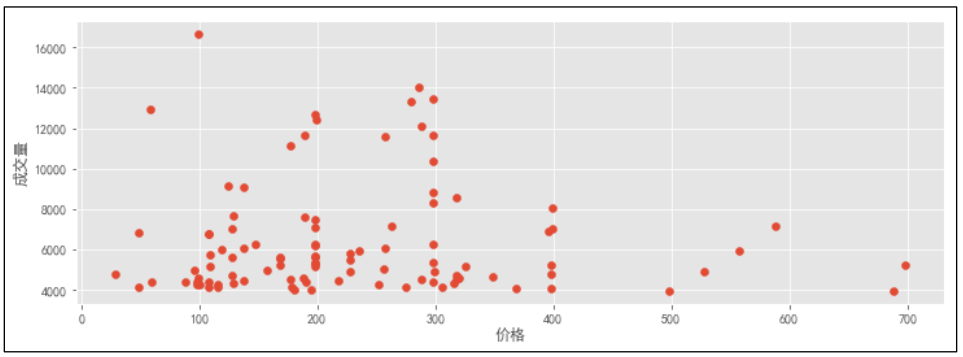

图 11-5

画散点图的方法和之前的方法不同，之前将图表的类型作为参数；而画散点图的时候，图表的类型作为一种方法，参数是要交叉的两个数据集（度量）。画散点图时，在画布 ax 上用 scatter 方法，其表达方式如下。

```
ax.scatter(df.价格,df.成交量)
```

11.2 pyecharts

11.2.1 Echarts 简介

Echarts 是由百度开发的一款开源免费，覆盖各行业图表的纯 JavaScript 的可视化库，其可以提供直观、生动、可交互和高度个性化定制的数据可视化图表，如图 11-6 所示。

Echarts 案例：http://echarts.baidu.com/examples.html

Echarts 具有丰富的图表类型，包括常规图、用于地理数据可视化的地图、用于关系数据可视化的关系图、还有用于 BI 的漏斗图和仪表盘，并且 Echart 支持图与图之间的混搭。

Echarts 特性是可以自由下载不同版本、不同主题和所需的地图数据，还可以在线定制模块，更多特性可以进入官网了解。

官方网址：http://echarts.baidu.com/feature.html#chart-types

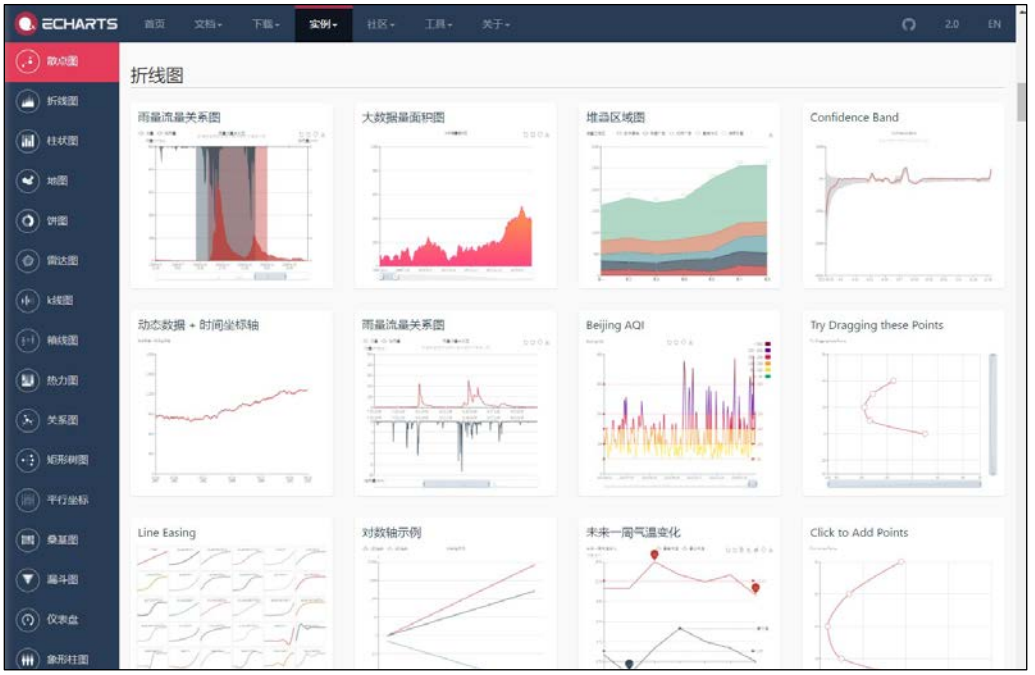

图 11-6

11.2.2　pyecharts 简介

pyecharts 是一个用于生成 Echarts 图表的类库，能利用几行代码轻松生成 Echarts 风格的图表。pyecharts 兼容 Python2 和 Python3。这里使用的版本为 0.2.3。

在 CMD 命令行提示行中，输入以下命令安装 Pyecharts，或者在 PyCharm 中进行安装。

```
pip install pyecharts
```

关于 pyecharts 的详细说明，可以访问 https://github.com/chenjiandongx/pyecharts 进行查阅。

11.2.3　初识 pyecharts，玫瑰相送

将随书的数据集 datas 文件夹拷贝到项目文件夹中，输入绝对地址后，再输入以下代码。

```
import json
from pyecharts import Pie
f = open("datas/pies.json")
data = json.load(f)
name=data['name']
sales=data['sales']
sales_volume=data['sales_volume']
```

```
    pie=Pie("衣服清洗剂市场占比",title_pos='left',width=800)
    pie.add("  成  交  量  ",name,sales_volume,center=[25,50],is_random=True,
radius=[30,75],rosetype='radius')
    pie.add("销售额",name,sales,center=[75,50],is_random=True,radius=[30,75],
rosetype='area',is_legend_show=False,is_label_show=True)
    pie.show_config()
    pie.render('D:/rose.html')
```

代码运行结果如图 11-7 所示。

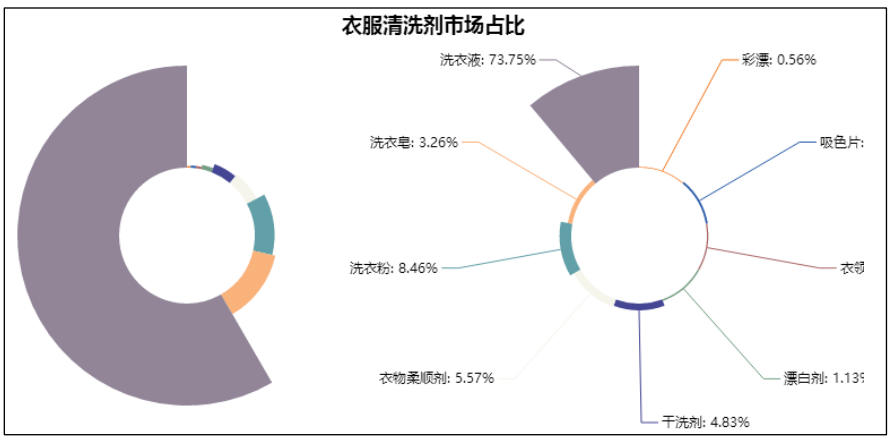

图 11-7

如果没有复制，则在使用 open 方法打开数据集的时候输入绝对地址，代码如下。

```
    f = open("D:/datas/pies.json")
```

11.2.4 pyecharts 基本语法

1. 图表大小以及标题设置

- 代码说明

```
    图表名称（"Title",title_pos="left/right/center",height=,width=）
```

Title 表示图表标题，title_pos 表示标题的位置，height 和 width 表示高度和宽度。

- 示例代码

```
    pie("衣服清洗剂市场占比",title_pos='left',width=800)
```

2. 图表内容设置

pyecharts 图表内容的设置主要通过 add()函数实现的。

- 代码说明

```
add("图名称",数据集 1,数据集 2,位置,颜色,图形类型,图例格式,标签设置)
```

- 示例代码

```
pie.add("成交量",name,sales_volume,center=[25,50],radius=[30,75],
visual_text_color='#fff', is_random=True,
rosetype='radius',
is_legend_show=False,
is_label_show=True,label_pos='outside',label_text_color='#000')
```

- 参数说明

（1）center　指定饼图圆心位置，第一个数值是 *X* 轴（从左到右）的位置，第二个数值是 *Y* 轴（从上到下）的位置，单位是%（百分比）。

（2）radius　指定饼图半径范围，第一个数值是圆心（同心圆）的半径，第二个数值是扇形的半径。

（3）visual_text_color　指定文本颜色。

（4）is_random　指定是否启用随机配色。

（5）rosetype　指定玫瑰图的图形类型。

（6）is_legend_show　指定是否显示图例。

（7）is_label_show　指定是否显示标签。

（8）label_pos　指定标签的位置。

（9）label_text_color　指定标签颜色。

3．图表配置显示

显示图表的配置信息用.show_config()方法。

示例：pie.show_config()

示例效果如图 11-8 所示。

图 11-8

4．图表输出

pyecharts 可以使用 render()函数将图表生成 HTML 文件。

该操作默认将会在根目录下生成一个 render.html 的文件，可以用浏览器打开该文件；也可保存

到指定路径下，如 render(" D:/rose.html ")。

11.2.5 基于商业分析的 pyecharts 图表绘制

1．分析背景：探索某电商市场衣物清洁剂各品类数据占比

（1）饼图

- 代码说明

```
pie.add("图例名称","属性名称","属性值",饼图半径-radius=,饼图圆心-center=,图形类型-rosetype-radius,area)
```

- 示例代码

```
import json
from pyecharts import Pie
f = open("datas/pies.json")
data = json.load(f)
name=data['name']
sales=data['sales']
sales_volume=data['sales_volume']
pie=Pie("",width=800)
pie.add("", name, sales, is_label_show=True)
pie.render('D:/pie.html')
```

代码运行结果如图 11-9 所示。

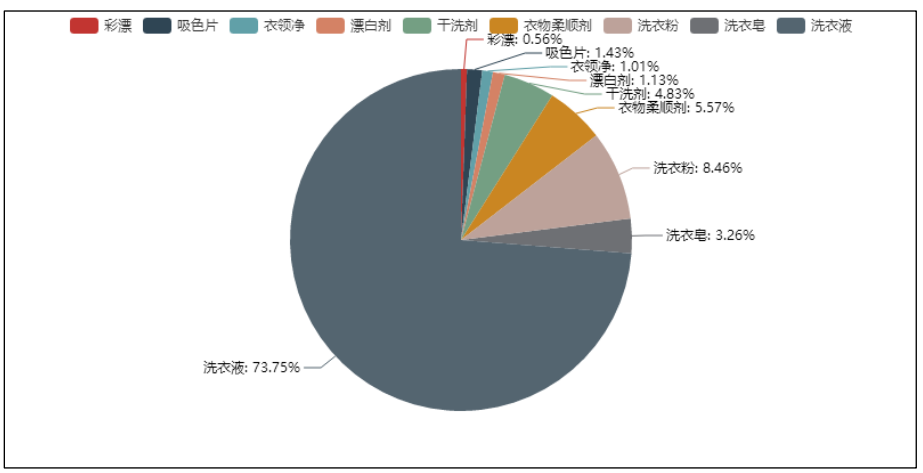

图 11-9

其他类型饼图，如玫瑰图（参见图 11-10）：其中左侧为 radius，扇区圆心角表示数据百分比；右侧为 area，仅通过半径展现数据大小。

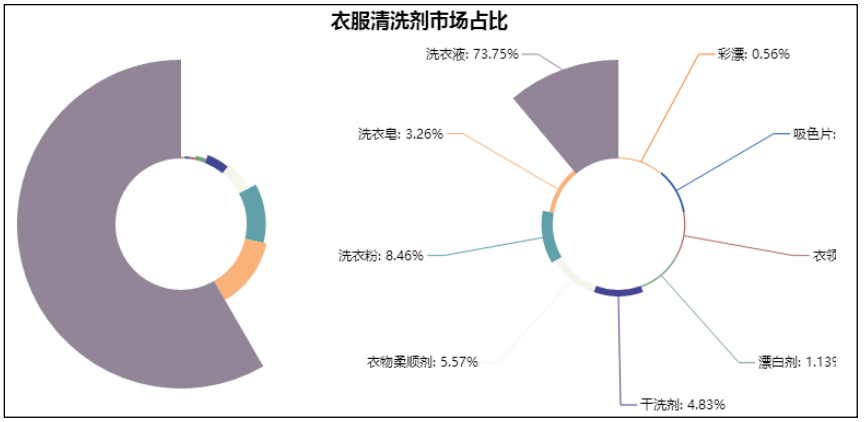

图 11-10

（2）漏斗图

- 代码说明

```
funnel.add("图例名称",属性名称,属性对应值,其他设置)
```

- 示例代码

```
from pyecharts import Funnel

funnle=Funnel("",width=800)
funnle.add(" 成 交 量 ",name,sales_volume,is_label_show=True,label_pos=
'inside',label_text_color='#fff')
funnle.render('D:/funnle.html')
```

代码运行结果如图 11-11 所示。

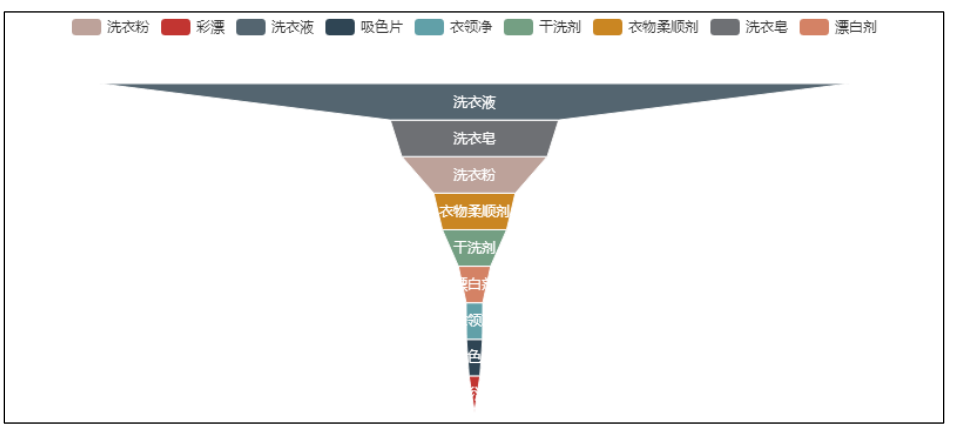

图 11-11

（3）柱形图

- 代码说明

```
bar.add("图例名称",横坐标轴数据,纵坐标轴数据,数据是否堆叠- is_stack=True or False,其他设置)
```

- 示例代码

```
from pyecharts import Bar

bar=Bar("衣服清洗剂市场占比柱形图",width=800)
bar.add("成交量",name,sales_volume,center=[25,50],mark_point=['average'])
bar.add("销售额",name,sales,center=[25,50],mark_point=['max','min'])
bar.render('D:/bar.html')
```

代码运行结果如图 11-12 所示。

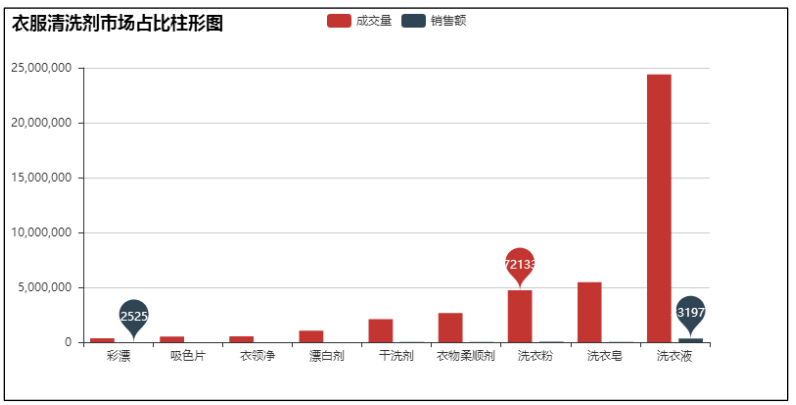

图 11-12

说明：mark_point 指定标记点，常用的有 3 个标记点，即最大值（max）、最小值（min）和平均值（average）。

```
bar.add("成交量",name,sales_volume,center=[25,50],mark_point=['average'] ,is_stack=True)
bar.add("销售额",name,sales,center=[25,50],mark_point=['max','min'],is_stack=True)
```

对于以上两句代码，柱形图默认是不进行堆叠的，如果想实现堆叠的效果，只需在 add()函数里添加代码 is_stack=True。

代码运行结果如图 11-13 所示。

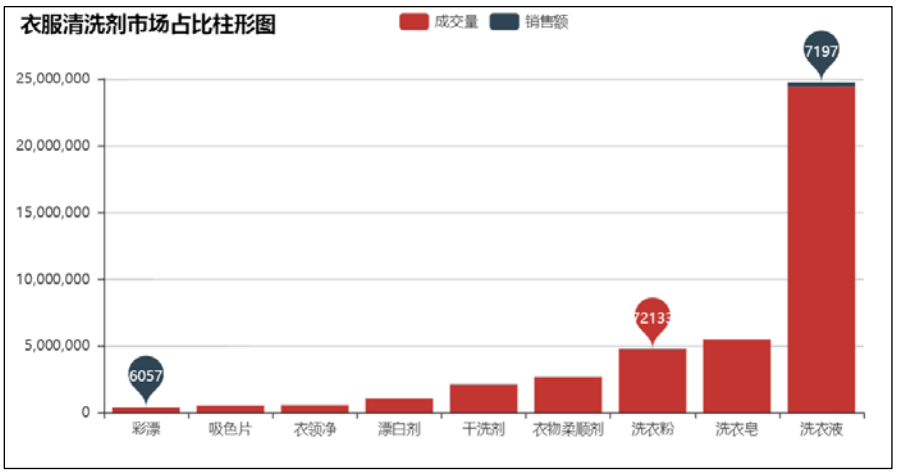

图 11-13

（4）条形图

- 代码说明

条形图其实就是将柱形图顺时针旋转 90 度，在这里只需为柱形图 add()函数中添加一句转换代码 is_convert=True 即可。

- 示例代码

```
bar=Bar("衣服清洗剂市场占比条形图",width=800)
bar.add("成交量",name,sales_volume,mark_point=['average'])
bar.add("销售额",name,sales,mark_point=['max','min'],is_convert=True)
bar.render('D:/bar_convert.html')
```

代码运行结果如图 11-14 所示。

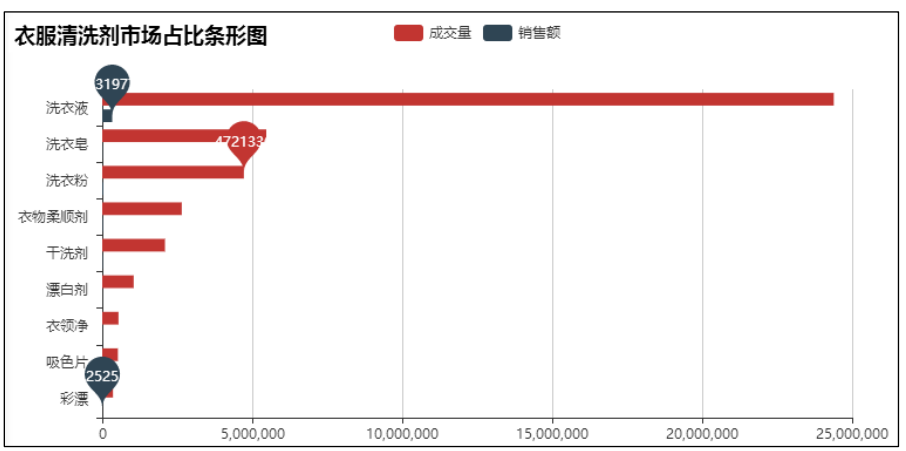

图 11-14

通过该条形图可以看出在某电商衣物清洁剂市场中，洗衣液的销量占比 73.75%，是市场容量最大的品类。

2．分析背景：探索某电商洗衣液市场趋势

接下来绘制折线图，并介绍几种特殊折线图的绘制方法。

（1）简单折线图

- 代码说明

```
line.add("图例名称",横坐标轴,纵坐标轴,是否显示图形标记- is_symbol_show,是否平滑曲线- is_smooth,是否堆叠-is_stack,是否为阶梯线图-is_step,是否填充曲线绘制面积-is_fill)
```

其中，is_symbol_show 默认为 True，其余都默认 False。

- 示例代码

```
import json
from pyecharts import  Line
f = open("datas/lines.json")
data = json.load(f)
date = data['date']
sales1 = data['sales1']
sales2 = data['sales2']
line = Line("洗衣液月销售情况")
line.add("成交量", date, sales1, mark_point=["average", "max", "min"], mark_point_symbol='diamond', mark_point_textcolor='#40ff27')
line.add("销售额", date, sales2, mark_point=["max"],is_smooth=True,mark_line=["max","average"],mark_point_symbol='arrow',mark_point_symbolsize=40)
line.render('D:/line.html')
```

代码运行结果如图 11-15 所示。

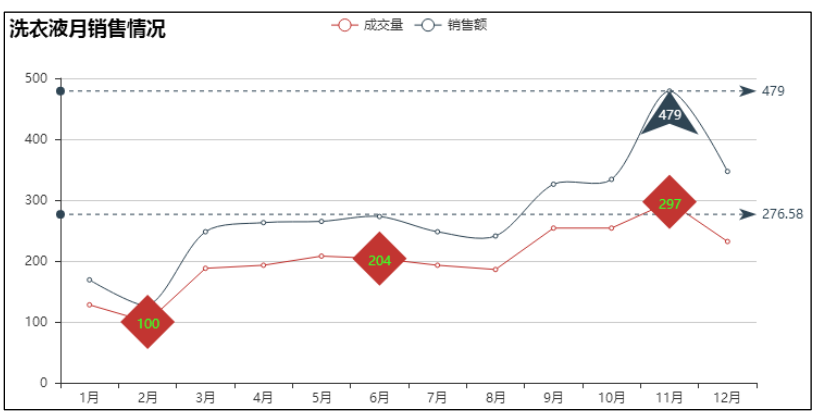

图 11-15

- 参数说明

mark_point_symbol	指定标签的形状。
mark_point_textcolor	指定标签的字体颜色。
mark_line	指定标记线。
mark_point_symbolsize	指定标记标记的大小。

（2）堆叠折线图

- 示例代码

```
    line.add("成交量", date, sales1, mark_point=["average", "max", "min"],
is_stack=True, is_label_show=True)
    line.add("销售额", date, sales2, mark_point=["max"],is_smooth=True,
mark_line=["max", "average"], is_stack=True, is_label_show=True)
    line.render('D:/linestack.html')
```

代码运行结果如图 11-16 所示。

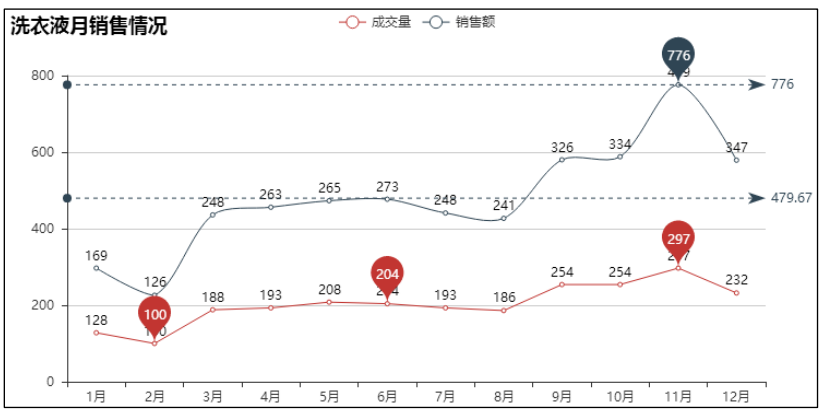

图 11-16

（3）阶梯折线

- 示例代码

```
    line.add("成交量", date, sales1, is_step=True, is_label_show=True)
    line.add("销售额", date, sales2, is_step=True, is_label_show=True)
    line.render('D:/linestep.html')
```

代码运行结果如图 11-17 所示。

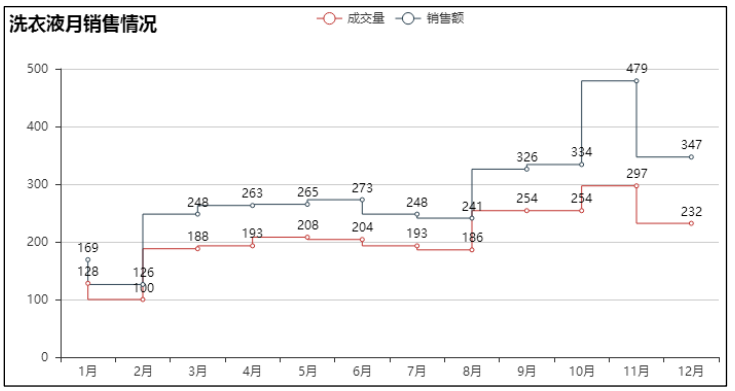

图 11-17

（4）面积折线图

- 示例代码

```
    line.add("成交量", date, sales1, is_fill=True, area_opacity=0.4)
    line.add("销售额", date, sales2, is_fill=True, area_opacity=0.2 ,
area_color='#000')
    line.render('D:/linefill.html')
    其中 area_opacity 指定透明比例
```

代码运行结果如图 11-18 所示。

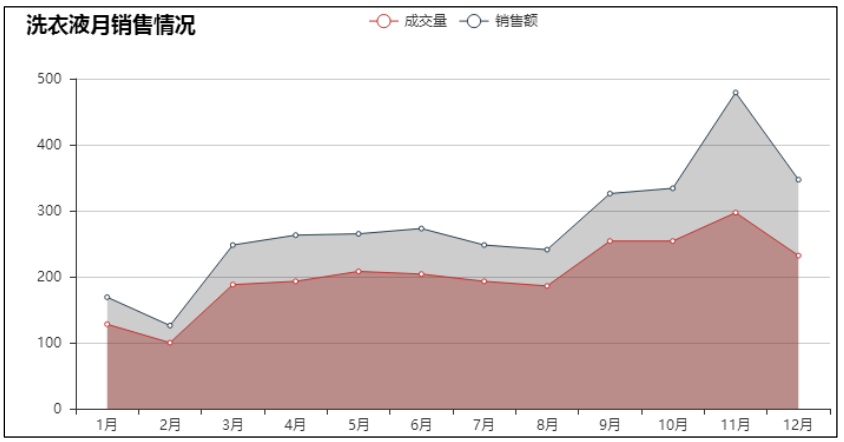

图 11-18

通过图表可以看出洗衣液在该电商网站秋冬季成交量的增长幅度较大。但根据生活常识，夏天人们出汗多，洗衣服的频率会更高，因此相应的洗衣液损耗较大。

通过业务理解，以下两方面的原因造成该网站秋冬季的成交量高于夏季的成交量。

第一，该网站从 9 月起有多个大型活动，由于价格比平时都要优惠，许多用户提前购买。

第二，进入秋季很多大件衣物，如大衣、被单、被子等需要集中清洗，对洗衣液的需求增大。

3．分析背景：指标完成情况

（1）仪表盘

- 代码说明

```
gauge.add("图例名称", "属性名称",属性值,仪表盘数据范围- scale_range 默认[0,100],仪表盘角度范围- angle_range 默认为[225,-45])
```

- 示例代码

```
from pyecharts import Gauge
gauge=Gauge('目标完成率')
gauge.add('任务指标','完成率',80.2)
gauge.render('D:/gauge.html')
```

代码运行效果如图 11-19 所示。

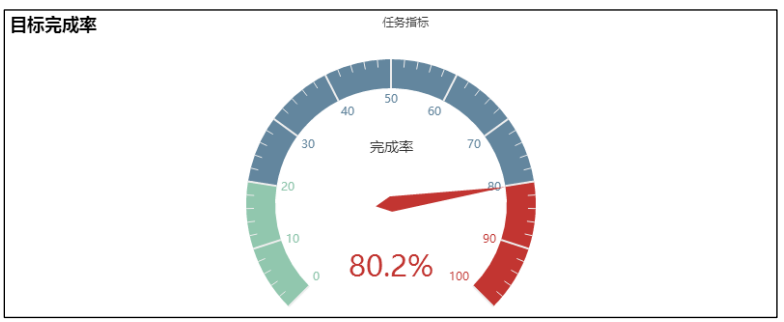

图 11-19

（2）水球图

- 代码说明

```
liquid.add（"图例名称",数据,水球外形-shape-默认 'circle'- 'rect'-'roundRect'-'triangle'- 'diamond'- 'pin'-'arrow'可选,波浪颜色- liquid_color,是否显示波浪画面- is_liquid_animation,是否显示边框- is_liquid_outline_show）
```

- 示例代码

```
from pyecharts import Liquid

liquid = Liquid("水球图")
liquid.add("水球", [0.8])
liquid.render('D:/liquid.html')
```

代码运行结果如图 11-20 所示。

图 11-20

4．分析背景：买家评价舆情分析

（1）词云

- 代码说明

worldCloud.add("图例名称"，"属性名称",属性值,词云图轮廓-shape-circle'、'cardioid'、'diamond'、'triangle-forward'、'triangle'、'pentagon'、'star'可选)

其中词间隔默认为 20- word_gap，词大小范围- word_size_range 默认为[12, 60]，词旋转角度-rotate_step 默认为 45。

- 示例代码

```
import pandas as pd
from pyecharts import WordCloud
wd=pd.read_csv("D:/cp.csv",header=0)
catename=[i[0]for i in wd[["关键词"]].values]
value=[int(i[0])for i in wd[["词频"]].values]
wordcloud=WordCloud(width=1200,height=600)
wordcloud.add("",catename,value,word_size_range=[10,120],shape='star')
wordcloud.render('D:/wordcloud.html')
```

代码运行结果如图 11-21 所示。

图 11-21

其中 word_size_range 指定字体大小范围。

通过词云可以看出消费者主要关注三点：一是包装，二是价格，三是正品（也可以视为品质）。

5．分析背景：探索销售额与高质宝贝数之间的关系

（1）散点图

- 代码说明

```
scatter.add("图例名称",横坐标轴数据,纵坐标轴数据,标记图形大小-symbol_size 默认10)
```

- 示例代码

```
from pyecharts import Scatter
import json
f = open("datas/scatters.json")
data = json.load(f)
xs = data['xs']
gb = data['gb']
scatter = Scatter("销售额与高质宝贝数")
scatter.add("关系", xs, gb)
scatter.render('D:/scatter.html')
```

代码运行结果如图 11-22 所示。

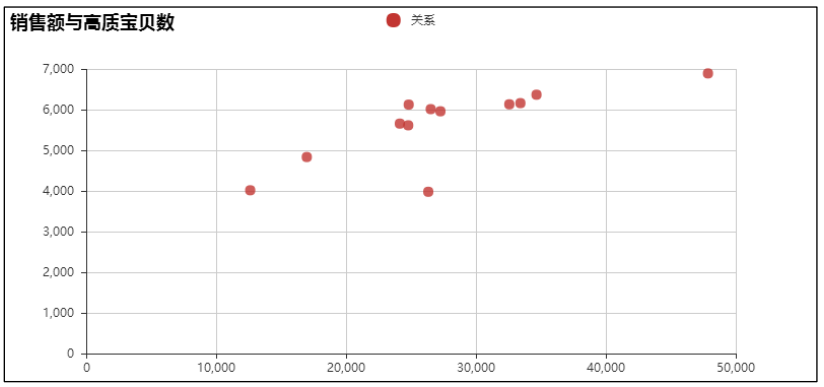

图 11-22

通过散点图可以看出销售额与高质宝贝数呈正相关趋势。

11.2.6　使用 pyecharts 绘制其他图表

（1）箱形图

箱形图是一种用作显示一组数据分散情况资料的统计图。它能显示出一组数据的最大值、最小值、中位数、下四分位数及上四分位数。

- 代码说明

```
Boxplot.add("图例名称",横坐标数据,纵坐标数据,其他设置)
```

- 示例代码

```
from pyecharts import Boxplot
boxplot = Boxplot("箱形图")
x_axis = ['销售额']
y_axis = [[169,126,248,263,265,273,248,241,326,334,479,347],]
_yaxis = boxplot.prepare_data(y_axis)
boxplot.add("boxplot", x_axis, _yaxis)
boxplot.render('D:/boxplot.html')
```

代码运行结果如图 11-23 所示。

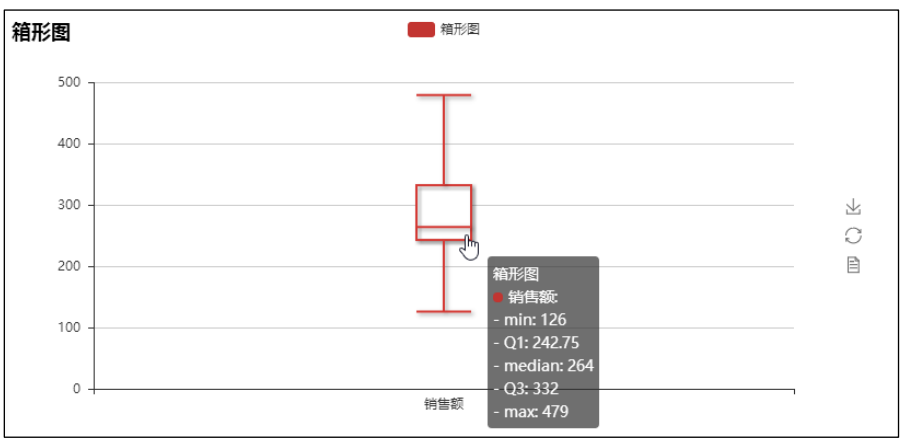

图 11-23

其中.prepare_data()方法表示求出最小值、下四分位数、中位数、上四分位数和最大值，然后用这五个数据画出箱形图。

（2）自定义组合图

Line-Bar 组合图，用 Overlap()将两个图形进行组合。

- 示例代码

```
from pyecharts import Bar,Line,Overlap
import json
f = open("datas/overlaps.json")
data = json.load(f)
date = data['date']
sales1 = data['sales1']
sales2 = data['sales2']
bar=Bar("Line-Bar")
```

```
    bar.add("Bar",date,sales1)
    line=Line()
    line.add("Line",date,sales2)

    overlap=Overlap()
    overlap.add(bar)
    overlap.add(line)
    overlap.render('D:/linebar.html')
```

代码运行结果如图 11-24 所示。

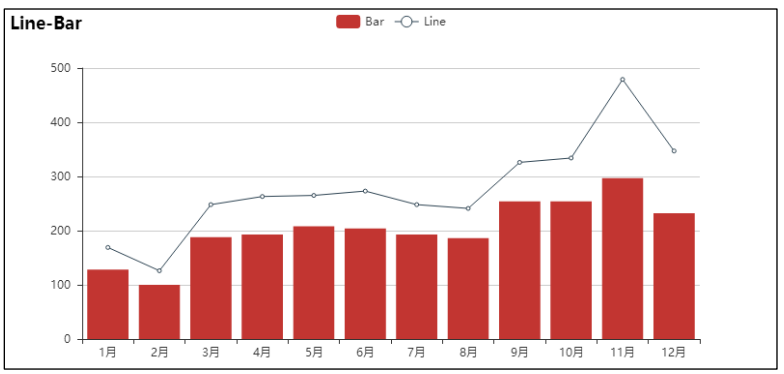

图 11-24

（3）3D 柱形图

- 代码说明

```
    Bar3D.add("图例名称",横坐标轴数据,纵坐标轴数据,数据集,柱透明度-默认 1 完全不透明,着色效果-color 只显示颜色没有光照等其他因素、lambert 带光照、realistic 真实渲染)
```

- 示例代码

```
    from pyecharts import Bar3D
    import json
    bar3d = Bar3D("3D 柱形图", width=1200, height=600)
    f = open("datas/bar3ds.json")
    datas = json.load(f)
    x_axis = datas['x_axis']
    y_axis = datas['y_axis']
    data = datas['data']
    range_color = datas['range_color']
    bar3d.add("", x_axis, y_axis, [[d[1], d[0], d[2]] for d in data],
is_visualmap=True,visual_range=[0, 20], visual_range_color=range_color)
    bar3d.render('D:/3dbar.html')
```

在该数据集中，[1, 2, 3] 表示 *X* 轴的索引为 1，即“10-20”；*Y* 轴的索引为 2，即“3”；*z* 轴的索引为 3。

代码运行结果如图 11-25 所示。

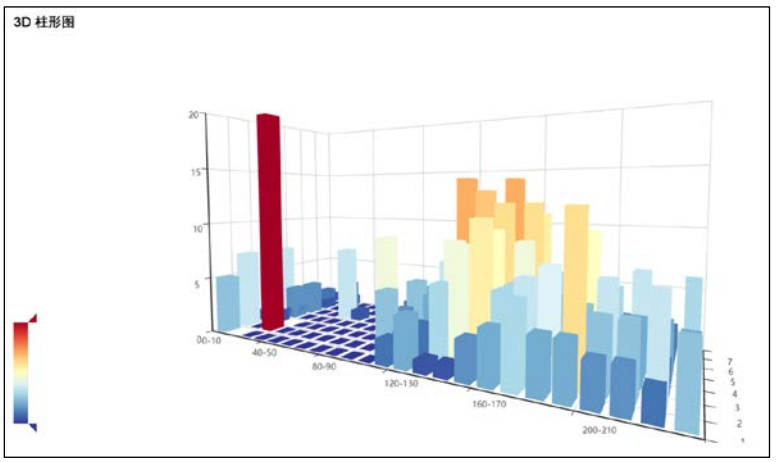

图 11-25

- 参数说明

is_visualmap	表示显示热力图。
visual_range	表示设置热力图示的数值上下范围。
visual_range_color	表示设置颜色方案。
通过设置 is_grid3d_rotate	可以启动自动旋转功能，代码如下。

```
    bar3d.add("", x_axis, y_axis, [[d[1], d[0], d[2]] for d in data],
is_visualmap=True,visual_range=[0,   20],   visual_range_color=range_color,
grid3d_width=200, grid3d_depth=80, is_grid3d_rotate=True)
```

通过设置 grid3d_rotate_speed，可以调节旋转速度，代码如下。

```
    bar3d.add("", x_axis, y_axis, [[d[1], d[0], d[2]] for d in data],
is_visualmap=True,  visual_range=[0,  20],  visual_range_color=range_color,
grid3d_width=200,grid3d_depth=80,is_grid3d_rotate=True,grid3d_rotate_speed=
180)
```

（4）用散点图绘制爱心

散点图可以基于基础图形画出和基础图形的散点图，这里用 scatter.draw 指定要画的基础图形，代码如下。

```
    from pyecharts import Scatter
    scatter = Scatter("爱心", width=800, height=480)
    data1 ,data2 = scatter.draw("D:/love.jpg")
```

```
scatter.add("Love", data1 ,data2)
scatter
```

代码运行结果如图 11-26 所示。

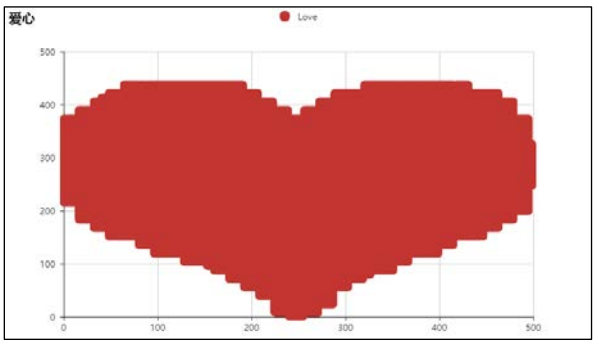

图 11-26

这里，scatter.draw 用于指定要画的基础图形。

11.2.7　pyecharts 和 Jupyter

下面在 CMD 命令提示行中输入命令，安装 pyecharts，命令代码如下。

```
conda install pyecharts
```

pyecharts 自动把 Echarts 脚本文件装在了 jupyter nbextensions 文件夹下面，pyecharts 已经进入全部离线模式，也就是在没有网络的情况下也能画图。而在 Jupyter 中，图片的输出只需要写图表名称即可，不需要相应的函数，如图 11-27 所示。

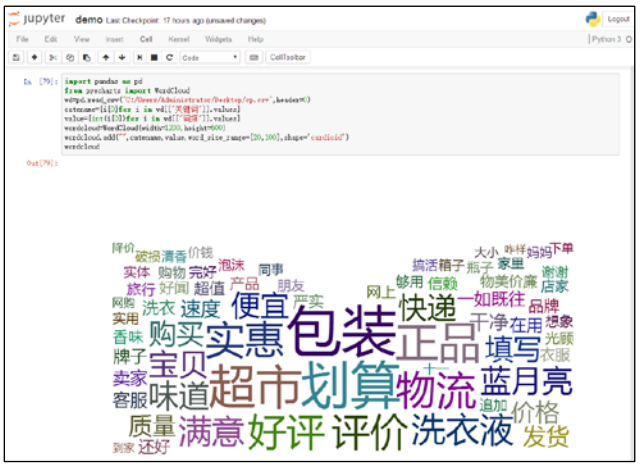

图 11-27

专业服务

电商数据分析咨询顾问服务：

帮助电商企业实现数据转型，让数据成为动力，拥抱新零售。包含搭建数据指标体系和数据库系统，搭建数据报表体系，建立商业分析体系等。

人工智能图像识别服务：

帮助企业应用人工智能技术提高产品设计开发能力，基于产品图片的精准识别识别产品特征元素，如服装的品类、围度、图案、廓形、袖口、门襟、长度、收口、背部等识别。

Python 课程：

基础入门、爬虫、数据清洗、可视化、机器学习、深度学习、自然语言分析、实战案例

电商数据分析课程：

数据分析方法论、数据获取爬虫、店铺诊断分析、市场分析、竞争分析、渠道分析、产品分析、会员分析、营销分析、库存分析、内容分析、数据化店铺规划布局、数据化排班设计、智能财务报表设计、店铺经营自动化报告设计

个人微信号：lingyishuju
自媒体公众号：零一
沐垚科技公众号：沐垚科技
访问沐垚科技：www.muyaotech.com
访问在线网校：www.01sjxy.com